

**Министерство высшего образования и науки Российской Федерации
Федеральное бюджетное государственное образовательное учреждение
высшего образования «Рязанский государственный радиотехнический
университет имени В.Ф. Уткина»**

На правах рукописи

Кузн-2-

КУЗНЕЦОВ Леонид Львович

**АЛГОРИТМЫ СЕГМЕНТАЦИИ РАДИОЛОКАЦИОННЫХ
ИЗОБРАЖЕНИЙ ДЛЯ ОПРЕДЕЛЕНИЯ ВОДНОЙ ПОВЕРХНОСТИ
И СУШИ В СИСТЕМАХ ОБРАБОТКИ ДАННЫХ ДИСТАНЦИОННОГО
ЗОНДИРОВАНИЯ ЗЕМЛИ**

Специальность 2.3.1. Системный анализ, управление и обработка
информации, статистика

**ДИССЕРТАЦИЯ НА СОИСКАНИЕ УЧЕНОЙ СТЕПЕНИ КАНДИДАТА ТЕХНИЧЕСКИХ
НАУК**

Научный руководитель
доктор технических наук,
доцент ГУСЕВ С.И.

Рязань – 2026

Оглавление

Введение	5
1. Анализ существующих методов и алгоритмов сегментации радиолокационных изображений систем ДЗЗ	12
1.1 Формирование высокодетальных радиолокационных изображений в современных системах ДЗЗ	12
1.2 Анализ современных подходов к сегментации радиолокационных изображений для определения водной поверхности и суши	16
1.3 Анализ основных алгоритмов кластеризации	19
1.4 Анализ алгоритмов поляриметрической классификации	21
1.5 Текстурный анализ радиолокационных изображений	31
1.6 Обоснование задач диссертационных исследований	35
Основные результаты.....	37
2. Алгоритмы сегментации радиолокационных изображений для определения водной поверхности и суши	39
2.1 Разработка детерминированного алгоритма кластеризации, обладающего высокой точностью и быстродействием	39
2.2 Применение алгоритма поляриметрической классификации Клода-Потье с использованием классификатора Уишарта для выполнения сегментации изображений на классы водной поверхности и суши	49
2.3 Оценка достоверности сегментации необработанных радиолокационных изображений на классы водной поверхности и суши	57
2.4 Отбор текстурных признаков Харалика для применения в алгоритме сегментации радиолокационных изображений	59

2.5 Алгоритм сегментации радиолокационных изображений для определения водной поверхности и суши	62
Основные результаты.....	76
3. Алгоритмы повышения достоверности сегментации радиолокационных изображений для определения водной поверхности и суши.....	77
3.1 Алгоритм комплексирования результатов сегментации многоканального радиолокационного изображения	77
3.2 Алгоритм формирования маски классов поверхности по результатам анализа относительных значений высот из цифровой модели рельефа	97
Основные результаты.....	115
4. Экспериментальные исследования разработанных алгоритмов сегментации радиолокационных изображений	116
4.1 Экспериментальное исследование алгоритма сегментации на основе детерминированного алгоритма кластеризации (Положение 1)	116
4.2 Экспериментальное исследование разработанного алгоритма комплексирования результатов сегментации многоканального изображения с помощью взвешенного голосования (Положение 2).....	119
4.3. Экспериментальное исследование алгоритма формирования маски классов поверхности по данным ЦМР (Положение 3)	123
4.4 Реализация специального программного обеспечения сегментации радиолокационных изображений для определения водной поверхности и суши	125
Основные результаты.....	126
Заключение.....	128
Список сокращений	130

Список литературы	131
Приложение.....	142

Введение

Актуальность темы. В настоящее время в системах дистанционного зондирования Земли (ДЗЗ) [1–8] для решения многих задач наряду с традиционным оптическим наблюдением все чаще используется радиолокационная съемка [9–11], позволяющая получать данные ДЗЗ в любое время суток и при наличии облачности. Одной из наиболее востребованных задач обработки радиолокационных данных является классификация двух объектов: водной поверхности и суши. Надежное определение границ данных классов необходимо во многих сферах, причем конкретные потребности могут отличаться. Например, в гидрологии, судоходстве, рыбном хозяйстве приоритет отдается выделению воды; в геологии, картографии и градостроительстве – определению суши.

Радиолокационные изображения трудно воспринимаемы человеческим зрением из-за зашумленности (например, спекл-шума [12]), наличия геометрических искажений объектов поверхности, эффектов затенения и отражения. Возникает необходимость обработки, позволяющей облегчить дешифрирование объектов наблюдаемой сцены. Актуальным решением является автоматизированное формирование маски классов водной поверхности и суши для каждого пикселя изображения, то есть его сегментация. Существующие алгоритмы не обеспечивают во многих практических приложениях достоверность решения указанной задачи. Актуальным направлением исследований является повышение достоверности сегментации водной поверхности и суши, чему и посвящена настоящая работа.

В диссертации предлагаются новые научно обоснованные технические решения в виде алгоритмов сегментации радиолокационных изображений для определения водной поверхности и суши. Они нацелены на повышение достоверности классификации этих объектов и востребованы во многих народно-хозяйственных приложениях.

Степень разработанности темы. Проблема сегментации радиолокационных изображений в системах ДЗЗ за рубежом начала активно исследоваться на данных от первых спутников с радиолокаторами с синтезированной апертурой антенны (РСА): SEASAT (1978 г., США); ERS-1, ERS-2 и ENVISAT (1991 г., 1995 г. и 2002 г., Евросоюз); RADARSAT-1 и RADARSAT-2 (1995 г. и 2007 г., Канада). Наибольшее развитие данная проблема получила с появлением поляриметрических РСА-систем в 1990-х годах. Основной вклад внесли ученые S.R. Cloude, E. Pottier, R.M. Goldstein, C.L. Werner, A.K. Dobson, L.E. Pierce, F.T. Ulaby, M. Moghaddam и др.

В СССР работы по данной тематике начаты в 1980-е годы при создании аппаратов «Космос-1500» (1983 г.), «Космос-1870» (1987 г.) и «Алмаз-1» (1991 г.). После распада СССР в этом направлении долгое время не было новых разработок, они стали появляться лишь в последнее десятилетие в рамках проектов серий «Аркон», «Кондор», «Обзор-Р» и др. Здесь ведущую роль заняли предприятия АО «РКЦ «Прогресс», АО «ВПК» НПО Машиностроения», Институт космических исследований РАН, РГРТУ и др., а также ученые и специалисты в области создания систем радиолокационного наблюдения Земли: В.С. Верба, В.Э. Турук, Л.Б. Неронский, О.Ю. Лаврова, Г.С. Кондратенков, В.Г. Коберниченко, О.В. Горячкин и др.

В настоящее время большинство предлагаемых алгоритмов сегментации радиолокационных изображений нацелены на выделение водной поверхности и основаны либо на кластеризации по методу k -средних, либо на машинном обучении. Основными недостатками кластеризации являются зависимость от начальной инициализации и возможность получения разных результатов при повторной обработке. Машинные алгоритмы требуют проведения обучения нейронной сети и ориентированы на сегментацию схожих с обучающей выборкой изображений. Таким образом, актуальным направлением исследований яв-

ляется разработка инвариантных к начальным условиям алгоритмов сегментации радиолокационных изображений для определения водной поверхности и суши, которые не требуют обучения и обеспечивают повторяемость и высокую достоверность получаемых результатов.

Цель диссертации – повышение достоверности и повторяемости алгоритмов сегментации радиолокационных изображений для определения водной поверхности и суши.

Объектом исследования служат алгоритмы сегментации радиолокационных изображений для определения водной поверхности и суши.

Предметом исследования являются информативные признаки объектов радиолокационных изображений и достоверность алгоритмов сегментации.

Для достижения поставленной цели решаются следующие **задачи**.

Задача 1. Анализ космических систем радиолокационной съемки, методов обработки радиолокационной информации и сегментации изображений.

Задача 2. Разработка алгоритма сегментации радиолокационных изображений для определения водной поверхности и суши, обладающего высокой повторяемостью и достоверностью результатов.

Задача 3. Разработка алгоритма комплексирования результатов сегментации многоканального радиолокационного изображения.

Задача 4. Разработка маски классов поверхности на основе анализа значений высот по данным цифровой модели рельефа (ЦМР).

Задача 5. Оценка разработанных алгоритмов на натурной информации от космических систем радиолокационной съемки Земли.

Научная новизна диссертации определяется тем, что в работе предложены и исследованы новые алгоритмы сегментации радиолокационных изображений для определения водной поверхности и суши, основанные на комплекс-

ном использовании текстурных, поляриметрических и топографических признаков объектов изображений, что позволяет повысить достоверность и повторяемость результатов сегментации.

Теоретическая и практическая значимость диссертации состоит в том, что разработаны и исследованы новые алгоритмы повышения достоверности и повторяемости сегментации водной поверхности и суши на радиолокационных изображениях, которые получили внедрение на практике.

Методы исследования. Теоретические результаты получены с использованием методов оптимизации, математической статистики, цифровой обработки изображений.

Соответствие паспорту специальности 2.3.1. Диссертация соответствует паспорту специальности 2.3.1. «Системный анализ, управление и обработка информации, статистика» в части:

– пункта 4 «Разработка методов и алгоритмов решения задач системного анализа, оптимизации, управления, принятия решений, обработки информации и искусственного интеллекта»;

– пункта 12 «Визуализация, трансформация и анализ информации на основе компьютерных методов обработки информации».

Новые научные положения, выносимые на защиту:

1. Алгоритм сегментации (АС) радиолокационных изображений для определения водной поверхности и суши с достоверностью сегментации не менее 90 % на основе алгоритма кластеризации, который обеспечивает повторяемость результатов при повторной обработке и повышение быстродействия на 35–50 %.

2. Алгоритм комплексирования результатов сегментации многоканального радиолокационного изображения с помощью взвешенного голосования, позволяющий повысить достоверность до 2,5 % по отношению к АС.

3. Алгоритм формирования маски классов поверхности по результатам анализа относительных значений высот из цифровой модели рельефа, позволяющий выполнить сегментацию с достоверностью не менее 93 % или повысить ее достоверность при наличии на изображении теневых склонов рельефа до 4,7 % по отношению к АС.

Степень достоверности и апробация. Достоверность полученных в диссертации результатов подтверждена корректным использованием математического аппарата, широкими исследованиями предложенных алгоритмов на статистически представительных данных натурной радиолокационной съемки.

По основным положениям и результатам исследований сделано 6 докладов на всероссийских и международных научно-технических конференциях: на международных конференциях «Современные технологии в науке и образовании» (Рязань, 2023, 2024, 2025), «Космические технологии» (Москва, 2024); на всероссийских конференциях «Новые информационные технологии в научных исследованиях» (Рязань, 2024), «Современные проблемы дистанционного зондирования Земли из космоса» (Москва, 2025).

Внедрение. Диссертационные исследования выполнены в Рязанском государственном радиотехническом университете им. В.Ф. Уткина (НИИ обработки аэрокосмических изображений – НИИ «Фотон») в рамках ОКР 16-13 по теме «Обзор-Р», определенной Федеральной космической программой (заказчик – АО «Ракетно-космический центр «Прогресс»). Предложенные решения получили внедрение в специальном программном обеспечении высокоуровневой обработки радиолокационной информации космического аппарата «Обзор-Р» №1, а также в учебном процессе РГРТУ. Это подтверждается соответствующими Актами.

Публикации. По теме диссертации опубликовано 14 работ: 4 статьи в изданиях по списку ВАК, 6 статей и тезисов докладов в материалах международных и всероссийских конференций, 4 свидетельства о регистрации программ для ЭВМ.

Личный вклад соискателя в опубликованных материалах состоит в следующем:

- в работе [13] соискателем выполнен анализ пригодности использования поляриметрической классификации Клода-Потье с использованием классификатора Уишарта для классификации объектов на радиолокационных изображениях;
- в работе [14] соискателем проведены экспериментальные исследования возможности применения поляриметрической классификации Клода-Потье с использованием классификатора Уишарта для обнаружения водной поверхности на полнополяризационных радиолокационных изображениях;
- в работе [15] соискателем разработана структура детерминированного алгоритма адаптивной кластеризации по максимумам гистограммы, обладающего высокой точностью кластеризации и быстродействием, о чем свидетельствуют приведенные в публикации экспериментальные исследования;
- в работе [16] соискателем проведено исследование достоверности сегментации при комплексировании результатов сегментации многоканальных радиолокационных изображений с помощью взвешенного голосования, показавшее лучший результат для данного способа по сравнению с другими алгоритмами;
- в работе [17] соискателем выполнена сегментация изображений на основе различных текстурных признаков Харалика, а также определены диапазоны границ между классами водной поверхности и суши;

- в работе [18] соискателем выполнено сравнение поляриметрической классификации Камерона с поляриметрической классификацией Клода-Потье при обработке радиолокационных изображений;
- работы [19–22] выполнены соискателем без соавторов.

Структура и объем работы. Диссертация состоит из введения, 4 глав, заключения, списка литературы и приложения. Основной текст работы включает 130 с., 50 рисунков и 44 таблицы. Список литературы содержит 109 наименований на 11 с., приложение – 7 с.

1. Анализ существующих методов и алгоритмов сегментации радиолокационных изображений систем ДЗЗ

В главе анализируются возможные способы формирования радиолокационных изображений в современных космических системах ДЗЗ и определяются ключевые параметры, необходимые для выполнения сегментации (на классы водной поверхности и суши). Выполняется анализ алгоритмов поляриметрической классификации и методов текстурного анализа, выбираются те, которые будут использованы в дальнейшем. Выявляются проблемные вопросы сегментации объектов, которые необходимо решить, и определяются направления научных исследований по созданию новых алгоритмов сегментации.

1.1 Формирование высокодетальных радиолокационных изображений в современных системах ДЗЗ

1.1.1. Радиолокаторы с синтезированной апертурой антенны. В настоящее время радиолокационная съемка в системах ДЗЗ осуществляется преимущественно с использованием радиолокаторов с синтезированной апертурой антенны (РСА) [23]. Результатом такой съемки является комплексный сигнал – радиоголограмма, – обработка которой позволяет получить выходное изображение [24].

Двигаясь по орбите, РСА периодически излучает линейно-частотно-модулированные (ЛЧМ) радиоимпульсы в направлениях вбок и вниз, а в паузах между излучениями принимает отраженные сигналы. Каждый принятый сигнал записывается как строка радиоголограммы, содержащая десятки тысяч комплексных отсчетов [9]. Положение сигнала в строке определяется наклонной дальностью L , связанной с быстрым временем t (интервалом между излучением и приемом импульса) соотношением $L = ct/2$, где c – скорость света. Каждая точка земной

поверхности отражает множество сигналов на протяжении азимутального времени θ , пока находится в зоне облучения РСА.

Импульсный отклик от точечной цели определяется как [9]

$$i_T(t, \theta) \approx C_T m_t \left(t - \frac{2L(\theta)}{c} \right) m_\theta(\theta - \theta_T) \times \exp \left(j\pi v_t \left(t - \frac{2L(\theta)}{c} \right)^2 \right) \exp \left(-j \cdot 2\pi f_0 \frac{2L(\theta)}{c} \right), \quad (1)$$

где C_T – комплексная константа,

$m_t(t) = \begin{cases} 1, & 0 \leq t \leq T, \\ 0, & t < 0 \text{ или } t > T \end{cases}$ – огибающая ЛЧМ-импульса длительностью T ,

$m_\theta(\theta)$ – огибающая сигнала в направлении азимута,

θ_T – момент времени, когда антенна РСА направлена строго на цель,

v_t – скорость изменения частоты излученного ЛЧМ-импульса,

f_0 – рабочая частота РСА,

j – мнимая единица.

Доплеровский эффект приводит к частотной модуляции отклика по азимуту; наклонная дальность L меняется с азимутальным временем θ , вызывая искривление отклика. Кроме того, модуляция излучаемых радиоимпульсов приводит к ЛЧМ сигнала по дальности [25]. В итоге импульсный отклик РСА представляет собой искаженный двумерный ЛЧМ-сигнал, после выпрямления дающий компактную в пространственной области автокорреляционную функцию. Сжатие этого отклика преобразует низкодетальную радиоголограмму в высокодетальное изображение.

1.1.2. Формирование высокодетального радиолокационного изображения. Фокусировка – это формирование высокодетального изображения из радиоголограммы. Данный процесс содержит три последовательных шага: сжатие импульсного отклика по дальности, устранение миграции по отсчетам дальности и сжатие по азимуту. На ранних этапах для этих целей применялись оптические

методы [10], которые в настоящее время заменила цифровая обработка радиолограммы. Различные способы устранения миграции по отсчетам дальности и сжатия по азимуту легли в основу множества алгоритмов фокусировки [26–38].

На рисунке 1 приведен пример радиолограммы, полученной при радиолокационной съемке Земли космической системой *Sentinel-1A*, и сформированного из нее высокодетального изображения.




Рисунок 1 – Действительная часть сигнала радиолограммы (слева) и амплитуда сигнала сформированного изображения (справа)

1.1.3. Геодезическая привязка изображения. У объектов радиолокационного изображения можно определить геодезическое положение. Сложность заключается в том, что эта задача имеет бесконечное множество решений, поскольку цель может находиться в любой точке дуги окружности радиуса r_0 . Такая окружность лежит в плоскости, перпендикулярной вектору скорости фазового центра антенны РСА в момент θ_{\perp} и проходящей через сам фазовый центр. Неопределенность убирается, если известна геодезическая высота цели относительно земной поверхности. В этом случае можно найти ее координаты в Гринвичской системе [10], после чего их пересчитать в геодезические широту и долготу по ГОСТ Р 51794-2008 [39].

1.1.4. Космические системы радиолокационной съемки Земли.

Наибольшие успехи в построении космических систем радиолокационной съемки Земли достигнуты за рубежом: в США, Канаде, Японии и Евросоюзе. В России такие системы начали разрабатываться относительно недавно, в настоящее время запущены аппараты серий «Кондор», «Кондор-ФКА» и «Обзор-Р».

Характеристики зарубежных и отечественных космических систем высокодетальной съемки представлены в таблице 1 [40–44]. Главное направление их развития – повышение разрешения съемки.

Таблица 1 – Характеристики космических систем высокодетальной радиолокационной съемки Земли

Космический аппарат	Страна	Год запуска	Длина волны, см	Режим съемки	Пространственное разрешение, м	Ширина полосы съемки, км
Sentinel-1A, 1B, 1C	Франция	2014, 2016, 2023	5,6	Stripmap	5	80
TerraSAR-X, TanDEM-X	Германия	2007, 2010	3,1	Staring Spotlight	0,25	4
				High Resolution Spotlight	1	10
				Spotlight	2	10
				Stripmap	3	30
RadarSat-2, RadarSat Constellation	Канада	2007, 2019	5,6	Ultra-Fine	2,8	20
				Wide Ultra-Fine	2,8	50
ALOS-2	Япония	2014	24	Spotlight	1–3	25
				Stripmap	3	50
Capella	США	с 2018	3,1	Spotlight	0,38–1,34	5
				Spotlight Wide	0,76–2,23	20
				Stripmap	1,13–3,37	5–10
Umbra-SAR	США	с 2020	3,1	Spotlight	0,25	5
ICEYE	Финляндия, США	с 2020 по 2025	3,1	Spotlight	0,5	15
				Stripmap	3	30
				Scan Wide	15, 27	100–200
				Dwell	0,25, 0,5, 1	5
NISAR	Индия, США	2025	9,4	SweepSAR	7, 3–24	более 240
			24		7, 3–48	
Gaofen-3-02, Gaofen-3-03	Китай	2021, 2022	5,5	Spotlight	1	10
				Strip	3–25	30–130

Космический аппарат	Страна	Год запуска	Длина волны, см	Режим съемки	Пространственное разрешение, м	Ширина полосы съемки, км
				ScanSAR	50–500	300–650
				Wave	10	5
				Extended	25	80, 130
Ludi Tance 1-01A/01B	Китай	2022	23	Stripmap	3–30	30–250
				ScanSAR	30	400
Кондор-Э, Кондор-ФКА	Россия	2014, 2023	9,5	Прожекторный	1–2	более 10
				Детальный непрерывный	1–3	более 10
Обзор-Р	Россия	2025	3,1	Высокодетальный кадровый	0,5–1	10
				Детальный кадровый	3	50
				Узкополосный маршрутный	3–5	30

1.2 Анализ современных подходов к сегментации радиолокационных изображений для определения водной поверхности и суши

1.2.1. Анализ современных решений. При сегментации радиолокационных изображений преимущественно ставится задача выделения воды. Предлагаемые методы можно разделить на две группы [45]: традиционные и на основе глубокого обучения.

Среди традиционных подходов наиболее часто используются:

- 1) кластеризация, преимущественно с помощью k -средних [46, 47] или S -средних [48]. Результаты кластеризации либо используются для формирования начальных условий, к которым применяются различные алгоритмы: слияния областей [49], метод опорных векторов [50], восстановления сверхразрешения [51] и др.; либо в качестве финального инструмента сегментации результатов текстурного анализа [52, 53] или другой предварительной обработки (фильтрации, выравнивания интенсивности и т.д.).

Основными преимуществами являются простота реализации и быстрое действие, а недостатком – зависимость результатов от числа кластеров;

- 2) модель активного контура [54], основанная на поиске минимального значения универсальной функции энергии, которая может строиться на основе краев [55, 56] или регионов [57]. Данный метод обеспечивает гладкие границы выделяемых объектов и устойчив к шуму, однако имеет большие вычислительные затраты и требует множества попыток для определения параметров оптимизации;
- 3) Марковские случайные поля [58], которые учитывают условное распределение каждого пикселя по соседним и позволяют качественно описать локальные статистические характеристики изображения для выполнения классификации. Главным недостатком является невозможность выполнения оперативной обработки из-за очень высокой вычислительной сложности;
- 4) статистические алгоритмы на основе классификатора Уишарта [59] или Байеса [58, 60]. Они хорошо работают при наличии высокой неоднородности, однако точность результатов сильно зависит от используемой статистической модели.

Применение глубокого обучения для сегментации радиолокационных изображений [61–63] подразумевает использование нейронных сетей, обученных на различных наборах данных. Такие алгоритмы обеспечивают высокую достоверность результатов, в том числе при большой шумовой составляющей, однако являются ресурсозатратными и сильно зависят от обучающей выборки.

1.2.2. Определение наиболее универсального метода сегментации. Так как практические результаты настоящей диссертации должны применяться в системах обработки данных ДЗЗ, важную роль играет возможность выполнения сегментации в режиме реального времени или близком к нему, поскольку во мно-

гих практических задачах необходимо оперативное получение результатов обработки для последующего анализа. В связи с этим, наиболее подходящим методом является кластеризация. Среди опций ее применения: к результатам обработки или в качестве начальных условий, – целесообразно использовать первый вариант, так как он учитывает информативность самого изображения, не внося потенциальные искажения в связи с возможными неоптимальными результатами кластеризации.

Отдельным вопросом является определение используемого алгоритма кластеризации. Основным недостатком популярных алгоритмов на основе k -средних (K-Means++, C-means и др.) является случайная инициализация центров кластеров, что при повторном анализе изображения может приводить к получению разных результатов сегментации. Такая вариативность снижает надежность сегментации, что ограничивает практическое применение алгоритма. В связи с этим актуальным является анализ алгоритмов кластеризации с целью определения возможных альтернатив, которые бы сохранили преимущества k -средних в плане скорости работы и простоты реализации, устранив его недостатки.

Так как основной целью работы является повышение достоверности сегментации на классы водной поверхности и суши, необходимо изучить и использовать информативные признаки объектов изображений. Поскольку радиолокационный сигнал характеризуется амплитудой и фазой, обе составляющие могут содержать полезную для решаемой задачи информацию. Поляриметрическая обработка учитывает каждую из них, поэтому может использоваться для определения классов объектов. Также целесообразно изучить разновидности текстурного анализа, поскольку данный вид обработки информации тоже используется в современных решениях.

1.3 Анализ основных алгоритмов кластеризации

1.3.1. Алгоритмы кластеризации. Кластеризация – одна из основных задач при сегментации изображений, которая позволяет разбить пиксели изображения на группы (кластеры), элементы которых имеют схожие свойства. Результаты такого разбиения в общем случае могут быть использованы при автоматической классификации объектов, определении границ, обнаружении водной поверхности, дистанционном зондировании и т.д. Точность разбиения пикселей изображения на кластеры может сильно влиять на интерпретируемость полученных результатов оператором или классификатором. Существующие алгоритмы кластеризации условно можно разделить на три основные группы, у каждой из которых есть свои внутренние ограничения:

1) точные алгоритмы с высокой вычислительной сложностью:

- алгоритм оптимизации Дженкса (Jenks Natural Breaks [47], JNB) обеспечивает математически оптимальную кластеризацию путем минимизации межклассовой дисперсии, но из-за сложности $O(n^2)$ (n – количество пикселей изображения) требует больших временных затрат и практически не применим к современным наборам данных, превышающим 10^6 элементов;
- алгоритмы серии k -средних (K-means [64] и K-means++ [65]) требуют $O(nki)$ вычислений, где i – число итераций, k – число кластеров, и характеризуются стохастической вариативностью и чувствительностью к инициализации (начальным положениям кластеров);
- алгоритм сдвига среднего значения (Mean Shift) [66, 67] использует сдвиг окна ядра к локальному максимуму плотности и хорошо выявляет кластеры произвольной формы без заранее заданного их числа, однако имеет сложность $O(i * n^2)$;

- иерархический алгоритм HDBSCAN [68, 69] на основе плотности, автоматически определяющий число кластеров и выделяющий шум; обладает сложностью $O(n \log n)$;
- алгоритм спектральной кластеризации [70, 71] на основе спектрального разложения матрицы сходства данных позволяет выявлять кластеры сложной формы, однако требует множества вычислений, в результате чего обладает сложностью $O(n^3)$;
- вероятностная модель смеси Гаусса (Gaussian Mixture Model, GMM) [72, 73] позволяет моделировать сложные распределения и относить объекты к кластерам и вероятностям и обладает вычислительной сложностью $O(inkd^2)$, где d – размерность признаков;

2) быстрые, но сильно упрощенные алгоритмы:

- равномерное (Equal-width binning) и равночастотное (Equal-frequency binning [74]) разбиения имеют низкую вычислительную сложность $O(n)$, но не могут адекватно работать с мультимодальными распределениями;
- алгоритм Оцу [75] обеспечивает наилучшее пороговое разделение для бимодальных гистограмм, но не может корректно обрабатывать сложные пиковые структуры, часто встречаемые в текстурном анализе [76];

3) специальные алгоритмы:

- медианный разрез (Median Cut [77]) превосходно подходит для квантования цветов, но плохо работает на данных не RGB-формата;
- алгоритмы, основанные на плотности, такие как DBSCAN [78], требуют тщательной настройки параметров и сталкиваются с трудностями при работе с кластерами однородной плотности.

В системах обработки данных ДЗЗ часто возникает потребность в оперативном получении результатов. Поскольку кластеризация является не един-

ственным шагом, выполняемым при сегментации изображений, необходимо использовать алгоритм с небольшим временем вычислений, обеспечивающий высокую точность. В качестве такого алгоритма может выступать K-Means++, который при малом числе кластеров (от 2 до 4) сходится достаточно быстро. В связи с этим большинство существующих решений по сегментации радиолокационных изображений основаны именно на нем.

1.3.2. Обоснование необходимости разработки собственного алгоритма кластеризации. Тем не менее, кластеризация на базе k -средних имеет существенный недостаток: результаты работы алгоритма сильно зависят от начальной инициализации центров кластеров, что может привести к некачественной обработке, в том числе, изображений, содержащих небольшое количество шумов и искажений. Это влечет за собой и другую особенность: при повторной сегментации одного и того же изображения из-за случайной инициализации центров кластеров результаты могут отличаться. Подобное поведение недопустимо, так как снижает надежность систем обработки данных ДЗЗ. Следовательно, возникает необходимость в разработке собственного алгоритма кластеризации, который обеспечивал бы полную повторяемость результатов, сохранив при этом достоинства k -средних – быстроедействие и высокую точность кластеризации.

1.4 Анализ алгоритмов поляриметрической классификации

Поскольку задача сегментации представляет собой классификацию каждого отдельного пикселя изображения и формирование итоговой маски, при изучении и создании алгоритмов сегментации в первую очередь речь будет идти о классификации, с помощью которой можно принять решение о принадлежности каждого пикселя тому или иному классу. Под самой сегментацией в дальнейшем

будет подразумеваться сформированная с определенной достоверностью маска классов пикселей.

1.4.1. Основные поляриметрические параметры. При радиолокационной съемке можно получить от одного до четырех изображений одной местности с разными видами поляризации сигнала при излучении и приеме: HH , VV , HV и VH (H – горизонтальная поляризация, V – вертикальная поляризация). В случае если РСА способен регистрировать все четыре набора поляризаций, он называется полнополяризационным [79], как и формируемое четырехканальное изображение. Основными характеристиками пикселей такого изображения являются матрица рассеяния S , или матрица Кенна, матрица ковариации C и матрица когерентности T .

Матрица рассеяния связывает падающую и рассеянную волны в линейном поляризационном базисе:

$$S = \begin{pmatrix} S_{HH} & S_{HV} \\ S_{VH} & S_{VV} \end{pmatrix}, \quad (2)$$

где S_{pq} – комплексный коэффициент обратного рассеяния для передаваемой поляризации q и принимаемой p .

Для статистической обработки случайно распределенных целей используются ковариационная матрица C и матрица когерентности T в базисе Паули, определяемые как:

$$C = \langle \Omega \Omega^{*T} \rangle, \Omega = [S_{HH}, \sqrt{2}S_{HV}, S_{VV}]^T, \quad (3)$$

$$T = \langle pp^{*T} \rangle, p = 1/\sqrt{2}[S_{HH} + S_{VV}, S_{HH} - S_{VV}, 2S_{HV}]^T, \quad (4)$$

где оператор $\langle \cdot \rangle$ – усреднение, оператор $*$ – комплексное сопряжение, оператор T – транспонирование.

Матрицы C и T связаны унитарным преобразованием и несут одинаковую информацию, но представление матрицы когерентности удобнее для физической интерпретации механизмов рассеяния.

1.4.2. Поляриметрическая декомпозиция Паули. Декомпозиция Паули позволяет определить типы рассеяния сигнала, что может использоваться для классификации объектов на изображениях. Для этого матрица рассеяния разлагается на сумму произведений элементов вектора Паули p следующим образом:

$$S = \frac{S_{HH}+S_{VV}}{\sqrt{2}} \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} + \frac{S_{HH}-S_{VV}}{\sqrt{2}} \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} + \sqrt{2}S_{HV} \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}. \quad (5)$$

Если обозначить элементы вектора Паули как a , b и c соответственно, то на их основе можно создать псевдоцветное изображение (для этого модули коэффициентов возводятся в квадрат). Обычно значения $|a|^2$ относят к красному каналу, $|c|^2$ – к зеленому, а $|b|^2$ – к синему [80]. Тогда поляриметрическое изображение в базисе Паули в достаточной мере соответствует визуальному восприятию человеком объектов изображения, поскольку вода представляется преимущественно синим цветом, а леса – зеленым. Изображение в базисе Паули представлено на рисунке 2.




Рисунок 2 – Пример декомпозиции Паули

1.4.3. Поляриметрические декомпозиция и классификация Камерона.

Декомпозиция Камерона [81] основана на двух фундаментальных физических свойствах цели – взаимности и симметричности. Свойство взаимности означает, что $S_{HV} = S_{VH}$, а свойство симметричности характеризуется наличием оси симметрии в плоскости, перпендикулярной направлению визирования радара.

Декомпозиция Камерона вычисляется следующим образом:

$$\vec{K} = A(\cos \varphi \vec{K}_{sym}^{max} + \sin \varphi \vec{K}_{asym}), \quad (6)$$

где A – общая амплитуда сигнала,

\vec{K}_{sym}^{max} – максимальная симметричная компонента,

\vec{K}_{asym} – асимметричная компонента,

φ – угол от 0° до 45° , показывающий степень симметричности цели.

Если цель признана симметричной ($\varphi < \frac{\pi}{8}$), ее максимальная компонента сравнивается с библиотекой из шести эталонных типов отражателей: трехгранного, двугранного, остроугольного двугранного, диполя, цилиндра и четвертьволновой пластины. Пример классификации по Камерону приведен на рисунке 3. Основным недостатком классификации Камерона является высокая чувствительность к шуму из-за когерентности метода: одна и та же местность может классифицироваться как разные типы отражателей от пикселя к пикселю.




Рисунок 3 – Пример классификации Камерона

1.4.4. Поляриметрические декомпозиция и классификация Клода-Потье. В основе декомпозиция Клода-Потье [82] лежит анализ матрицы когерентности. После ее разложения определяются три параметра: энтропия H , анизотропия A и угол рассеяния α . Энтропия характеризует меру случайности механизмов рассеяния внутри одного пикселя; анизотропия учитывается только при высокой энтропии и позволяет определить, присутствует ли еще один ярко выраженный механизм рассеяния, помимо главного; угол рассеяния является физическим индикатором типа доминирующего механизма рассеяния.

Если α имеет около нулевое значение, то рассеяние поверхностное, что характерно гладким поверхностям, таким как вода и дороги. При угле рассеяния около 45° говорят о объемном (дипольном) рассеянии, присущем растительности. Когда значения угла максимальны (около 90°), имеет место двукратное рассеяние, свойственное искусственным уголковым отражателям, например, зданиям и мостам. На рисунке 4 приведен результат декомпозиции Клода-Потье в псевдоцвете, где красному каналу соответствует α , зеленому – H , синему – A .




Рисунок 4 – Результат декомпозиции Клода-Потье

Основным назначением декомпозиции Клода-Потье является неконтролируемая классификация объектов на полнополяриметрическом наборе радиолокационных изображений. Каждый пиксель, в зависимости от значений энтропии и угла рассеяния, относится к одной из девяти зон (Рисунок 5). При этом зона 9 является запрещенной, так как не существует объектов с подобными характеристиками рассеяния, поэтому на практике обычно речь идет о формировании 8 классов.




Рисунок 5 – Зоны классов объектов, выделяемые в плоскости H/α

Классификация Клода-Потье может использоваться в задаче выделения водной поверхности на изображении. В зону 3 попадает спокойная вода и асфальтированные дороги, а в зону 6 – вода с сильным волнением и шероховатая почва. Объединение разнородных типов объектов в одинаковые классы является основным недостатком такой классификации, хотя ее устойчивость к спекл-шуму намного выше, чем у классификации Камерона. Пример классификации Клода-Потье приведен на рисунке 6.




Рисунок 6 – Результат неконтролируемой поляриметрической классификации Клода-Потье при формировании 8 классов

Также, если учитывать влияние анизотропии, количество формируемых классов можно увеличить до 16 (Рисунок 7). В таком случае обычно первым восьми классам соответствует низкая анизотропия ($A < 0,5$), а вторым – высокая. Несмотря на то, что подобная классификация позволяет выделить большее число типов объектов, интерпретация результатов сильно затрудняется.




Рисунок 7 – Результат неконтролируемой поляриметрической классификации Клода-Потье при формировании 16 классов

1.4.5. Поляриметрическая классификация Клода-Потье с использованием классификатора Уишарта. Наиболее широкое распространение получил метод, в котором результаты классификации Клода-Потье уточняются с помощью классификатора Уишарта [59, 83]. Для каждого пикселя изображения рассчитывается расстояние до центра каждого кластера на основе статистической меры правдоподобия – расстояние Уишарта. С его помощью определяется, какому кластеру наиболее вероятна принадлежность данного пикселя (чем значение меньше, тем вероятность выше). Указанная процедура повторяется итерационно, пока не выполнится условие остановки алгоритма.

Результаты работы данного алгоритма приведены на рисунке 8. Шумовая составляющая значительно уменьшилась и разные по физической природе объекты разнесены по разным классам, однако вследствие переклассификации некоторые пиксели отнесены к классам, физическими свойствами рассеяния которых они не обладают.




Рисунок 8 – Результат классификации Клода-Потье с использованием классификатора Уишарта

1.4.6. Определение лучшего алгоритма поляриметрической классификации для решения целевой задачи. Таким образом, можно сделать вывод о том, что задача поляриметрической классификации до сих пор до конца не решена. Все рассмотренные алгоритмы устраняли главные недостатки предыдущих, однако имели свои собственные, которые также в определенных ситуациях могут стать критичными. Тем не менее, наиболее универсальным является алгоритм с обучением классификатора Уишарта по результатам классификации Клода-Потье. Исходя из физического смысла выделенных зон и соответствующих им классов, можно выполнить поляриметрическую классификацию и объединить пиксели классов 3 и 6 в класс водной поверхности, а остальные – в класс суши, что позволит провести требуемую сегментацию без необходимости применения алгоритма кластеризации.

1.5 Текстуальный анализ радиолокационных изображений

1.5.1. Текстуальный анализ изображений. Текстуальный анализ – направление обработки изображений, целью которого является количественное и качественное описание пространственной организации яркостей пикселей в изображении. Текстура характеризует закономерности повторяемых локальных структур (паттернов) и позволяет выделять объекты или поверхности с одинаковыми свойствами. Для данных радиолокационной съемки текстурные признаки позволяют дополнить радиофизические характеристики поверхности (например, коэффициент обратного рассеяния) информацией о локальных изменениях сигнала, что повышает эффективность сегментации и классификации [84, 85].

В РСА-изображениях текстура формируется не только из-за свойств отражающей поверхности, но и в результате интерференционного спекл-шума, возникающего при когерентной обработке сигнала [86]. Поэтому перед извлечением текстурных признаков часто применяют адаптивную фильтрацию, чтобы снизить влияние шума и сохранить особенности структуры [87–89].

При выполнении текстурного анализа важное значение имеет выбор размера окна, поскольку изображение, обработанное малым окном, имеет высокую зашумленность, а изображение, обработанное большим окном, утрачивает информацию о локальных особенностях поверхности [90].

1.5.2. Основные методы определения текстурных признаков. Существует несколько классов методов определения текстурных признаков:

- 1) Статистические методы – оценивают распределение яркостных значений и их взаимосвязь. К ним относятся:
 - Матрица смежности уровней серого, или матрица яркостной зависимости, (Gray-Level Co-occurrence Matrix, GLCM) [84] – позволяет извлекать ряд признаков (контраст, энтропия, энергия, гомогенность, корреляция и т.д.);

- Автокорреляционные функции – анализируют регулярность повторения текстурных элементов;
 - Локальные статистики (математическое ожидание, дисперсия, ковариация) на скользящих окнах;
- 2) Спектральные методы – анализируют пространственные частоты в изображении [85]. К ним относятся:
- Преобразование Фурье – выделяет доминирующие частотные компоненты;
 - Преобразование Габора – выполняет локализованный частотно-пространственный анализ;
 - Вейвлет-анализ – осуществляет многомасштабное представление текстуры;
- 3) Модельные методы – описывают текстуру как реализацию стохастической или фрактальной модели. К ним относятся:
- Модели Маркова (Марковские случайные поля – Markov Random Field, MRF) – используют условную зависимость между пикселями;
 - Фрактальная размерность – применяется для оценки самоподобных структур;
- 4) Морфологические методы – используют операции математической морфологии для описания формы и распределения текстурных элементов (морфологические профили, морфологические спектры) [91].

1.5.3. Матрица смежности уровней серого. Для применения в текстурном анализе PCA-изображений [52, 53] наибольшее распространение получил статистический метод на основе матрицы смежности уровней серого, предложенный М. Хараликом в 1973 году. Эта матрица представляет собой оценку плотности распределения вероятностей второго порядка, полученную по изображению в предположении, что плотность вероятности зависит лишь от расположения двух

пикселей. Размер матрицы определяется количеством градаций яркости изображения, а значение каждого элемента равняется встречаемости пары пикселей с соответствующими значениями интенсивностей в заданных позициях друг относительно друга [92].

Построение матрицы P размером $L \times L$ для L квантованных значений яркости текстуры изображения с матрицей яркости I выполняется по следующему правилу [93]:

$$P_{r,\theta}(i,j) = |\{(k,s), (t,v): I(k,s) = i, I(t,v) = j\}|, \quad (7)$$

где i, j – уровни яркости матрицы $P(i, j = \overline{1, L})$,

$I(k, s)$ и $I(t, v)$ – значения элементов матрицы яркости с координатами (k, s) и (t, v) ,

r – расстояние между элементами $I(k, s)$ и $I(t, v)$,

θ – угол между элементами $I(k, s)$ и $I(t, v)$ относительно горизонтальной оси, т.е. направление [94, 95].

Преимуществами GLCM являются:

- 1) чувствительность к пространственным взаимосвязям пикселей: в отличие от простых статистик первого порядка (математическое ожидание, дисперсия) GLCM учитывает взаимное расположение значений яркости в заданном направлении и на определенном расстоянии, что позволяет описывать структурную упорядоченность и неоднородность сцены;
- 2) гибкость задаваемых параметров (можно варьировать шаг смещения, направление, размер окна, количество уровней квантования), что позволяет адаптироваться к разным масштабам и типам текстур на изображениях;
- 3) компактный набор основных признаков по Харалику образует информативный вектор признаков, удобный для машинного обучения и статистической классификации;

- 4) простота реализации и умеренная вычислительная сложность, что особенно важно при обработке радиолокационных изображений больших объемов данных.

Многочисленные исследования [90, 96] показали, что добавление текстурных признаков GLCM к радиофизическим характеристикам (например, коэффициенту обратного рассеяния), повышает точность распознавания типов поверхности на 10–20 %, по сравнению с использованием только амплитудной информации.

1.5.4. Определение текстурных признаков для решения целевой задачи. На основе ранее указанной информации было принято решение в дальнейшем использовать именно текстурные признаки по Харалику, как наиболее подходящие для решения поставленной задачи сегментации РСА-изображений. В своей работе [84] Харалик выделил 14 текстурных признаков, которые могут быть рассчитаны по GLCM: второй угловой момент, контраст, корреляция, дисперсия, обратный дифференциальный момент, сумма средних, сумма дисперсий, сумма энтропий, энтропия, дисперсия разностей, дисперсия энтропий, две информационные меры корреляции, а также максимальный коэффициент корреляции. Для решения поставленной задачи сегментации радиолокационных изображений с целью определения водной поверхности и суши в дальнейшем имеет смысл использовать только те признаки, в которых водная поверхность и суша имеют наибольшие отличия. Такие признаки должны отражать однородность и низкую текстурную сложность, поскольку на радиолокационных изображениях водные поверхности обычно имеют низкий уровень обратного рассеяния и выглядят однородными, в то время как суша почти всегда более структурирована. Отбор подходящих текстурных признаков требует проведения дополнительных исследований.

1.6 Обоснование задач диссертационных исследований

1.6.1. Разработка детерминированного алгоритма кластеризации. В п. 1.3.2 сделан вывод о необходимости разработки алгоритма кластеризации, устраняющего основной недостаток широко распространенных стохастических алгоритмов серии k -средних – зависимость результатов кластеризации от начальных условий и, как следствие, возможность получения отличающихся результатов при выполнении повторной обработки. При этом ставится задача сохранить их преимущества – быстродействие и точность. Разработке такого детерминированного алгоритма кластеризации посвящен раздел 2.1 настоящей диссертации.

1.6.2. Определение направления исследований поляриметрической классификации. На основе анализа алгоритмов поляриметрической классификации, выполненного в разделе 1.4, установлено, что классификация Клода-Потье с использованием классификатора Уишарта на сегодняшний день позволяет получать результаты с наименьшим числом ошибок. Так как информация о формируемых классах известна, применение алгоритма кластеризации не требуется, следует лишь убедиться в возможности получения высокой достоверности сегментации радиолокационных изображений на классы водной поверхности и суши при использовании описанного в п. 1.4.6 разбиения классов на две группы. Решению данной задачи посвящен раздел 2.2 настоящей диссертации.

1.6.3. Определение направлений исследований по разработке алгоритма сегментации на основе детерминированной кластеризации. В п. 1.2.2 для выполнения сегментации принято решение о применении алгоритма кластеризации к результатам предварительной обработки изображения, а не в качестве начальных условий. В связи с этим, следует убедиться в том, что сегментация по исходному радиолокационному изображению не позволяет достичь высокой достоверности.

В разделе 1.5 в качестве предварительной обработки изображения обосновано использование текстурных признаков Харалика. В связи с многообразием предложенных им признаков, необходимо осуществить отбор тех, которые позволяют получить наибольшую достоверность сегментации. Далее результаты текстурного анализа должны быть подвергнуты кластеризации по разработанному детерминированному алгоритму. Следовательно, необходимо определить диапазоны значений, в соответствии с которыми будет приниматься решение о принадлежности каждого сформированного кластера водной поверхности или суши. Также необходимо удостовериться, что достоверность получаемых результатов сегментации не хуже, чем у ближайшего аналога.

Оценка достоверности сегментации исходных радиолокационных изображений выполняется в разделе 2.3, отбор текстурных признаков Харалика – в разделе 2.4, определение диапазонов значений классов и оценка достоверности – в разделе 2.5 настоящей диссертации.

1.6.4. Определение направлений исследований по повышению достоверности сегментации. С целью повышения достоверности сегментации следует разработать способ комплексирования результатов нескольких сегментаций. Для этого необходимо определить, каким образом принимать решение о классе пикселей, после чего можно будет использовать различные источники информации для формирования единых результатов. Указанные задачи решаются в разделе 3.1 настоящей диссертации.

Кроме того, можно использовать априорную топографическую информацию из цифровой модели рельефа, которая содержит низкодетальные данные о высотах земной поверхности. Поскольку радиолокационные изображения позволяют осуществить геодезическую привязку, имеется возможность сопоставить фрагмент ЦМР со сценой анализируемого изображения. Раздел 3.2 настоящей диссертации посвящен использованию данных из ЦМР для сегментации радиолокационных изображений.

1.6.5. Оценка достоверности сегментации. Все перечисленные направления работ требуют оценки достоверности сегментации для подтверждения: 1) возможности сегментации водной поверхности и суши; 2) результативности в повышении достоверности сегментации. Расширенные экспериментальные исследования по данным вопросам приведены в главе 4 настоящей диссертации.

1.6.6. Выводы. Таким образом, новыми научными исследованиями, составляющими основу диссертации и выносимыми на защиту, являются:

- разработка алгоритма сегментации радиолокационных изображений для определения водной поверхности и суши на основе детерминированного алгоритма кластеризации;
- разработка алгоритма комплексирования результатов сегментации многоканального радиолокационного изображения;
- разработка алгоритма формирования маски классов поверхности по результатам анализа значений высот из ЦМР для выполнения сегментации радиолокационных изображений.

Основные результаты

1. Рассмотрены особенности формирования высокодетального изображения из получаемой с помощью РСА информации. Изучены космические системы высокодетальной радиолокационной съемки Земли.

2. Осуществлен анализ современных подходов к сегментации радиолокационных изображений. В качестве наиболее пригодной для оперативной обработки в системах ДЗЗ определена сегментация на основе кластеризации результатов предварительной обработки изображения с помощью алгоритмов на основе k -средних. Для повышения достоверности сегментации принято решение использовать текстурные и поляриметрические информативные признаки объектов радиолокационных изображений.

3. Выполнен анализ основных алгоритмов кластеризации. Установлено, что наиболее часто используемая кластеризация по методу k -средних проста в реализации, однако не гарантирует повторяемость получаемых результатов при повторной обработке изображения. Данная особенность снижает надежность систем обработки данных ДЗЗ, поэтому принято решение о разработке детерминированного алгоритма кластеризации, лишенного указанного недостатка.

4. Проведено сравнение алгоритмов поляриметрической классификации. В качестве используемой выбрана классификация Клода-Потье с обучением классификатора Уишарта. Предложен подход к выполнению сегментации для определения водной поверхности и суши без кластеризации на основе объединения классов в две группы по их физическим свойствам.

5. Выполнен анализ методов текстурного анализа радиолокационных изображений. Обоснован выбор матрицы смежности уровней серого Харалика в качестве используемого способа предварительной обработки изображений.

6. Определены направления диссертационных исследований, касающиеся разработки алгоритмов сегментации радиолокационных изображений на классы водной поверхности и суши на основе поляриметрических и текстурных информативных признаков объектов изображений. Поставлена задача повышения достоверности сегментации путем комплексирования результатов сегментации многоканального радиолокационного изображения. Обоснована перспективность использования информации из ЦМР для выполнения сегментации. Поставлена задача подтверждения качественных характеристик разработанных алгоритмов путем оценки достоверности сегментации на статистически представительной выборке данных.

2. Алгоритмы сегментации радиолокационных изображений для определения водной поверхности и суши

Глава посвящена разработке алгоритмов сегментации радиолокационных изображений для определения водной поверхности и суши. Разрабатывается детерминированный алгоритм адаптивной кластеризации по максимумам гистограммы (АКМГ) для устранения главного недостатка существующих решений на основе k -средних. Определяется возможность применения алгоритма поляриметрической классификации Клода-Потье с использованием классификатора Уишарта для сегментации изображений на целевые классы. Производится отбор текстурных признаков Харалика, обеспечивающих наибольшую достоверность сегментации. Разрабатывается алгоритм сегментации, основанный на применении АКМГ к результатам текстурного анализа.

2.1 Разработка детерминированного алгоритма кластеризации, обладающего высокой точностью и быстродействием

2.1.1. Формирование ядра алгоритма. Основной статистической характеристикой изображения является гистограмма, которая показывает количество пикселей каждой интенсивности. Радиолокационное изображение, полученное при обработке сигнала с определенным видом поляризации, является одноканальным, то есть отображается в оттенках серого. При L возможных значениях интенсивности пикселей гистограмма такого изображения рассчитывается по формуле:

$$h[l] = \sum_{i=1}^W \sum_{j=1}^H \delta(I(i, j), l), \quad l = 0, 1, 2, \dots, L - 1, \quad (8)$$

где $h[l]$ – число пикселей с интенсивностью l ,

W и H – ширина и высота изображения,

$I(i, j)$ – интенсивность пикселя в точке (i, j) ,

$$\delta(a, b) = \begin{cases} 1, & a = b \\ 0, & a \neq b \end{cases} \text{ – дельта-функция Кронекера.}$$

Можно сделать предположение, что пиксели, сосредоточенные вокруг максимумов (пиков) гистограммы, имеют схожие свойства, на основании чего могут быть объединены в кластеры. При этом глобальный максимум гистограммы содержит наиболее важную информацию (в случае, если он не вызван импульсной помехой), поэтому его следует назначить центром первого кластера (т.е. первым центроидом), а остальные центроиды формировать, исходя из конкретной формы гистограммы.

В случае если гистограмма содержит более одного максимума, оставшиеся целесообразно продолжать использовать в качестве центроидов, так как они являются центрами естественной группировки данных. При этом следует учитывать два момента:

- 1) выбор в качестве центроидов пиков, которые расположены близко друг к другу, даже если они имеют большую величину, может привести к тому, что пиксели изображения, которые фактически представляют один кластер, разбиваются на несколько, тем самым вводя излишнюю детализацию в одном поддиапазоне гистограммы и потенциально приводя к потере уникальных кластеров в других поддиапазонах;
- 2) выбор в качестве центроидов пиков, которые имеют малую величину, может привести к выделению кластеров, которые несут небольшую информационную составляющую или даже являются шумом, тем самым потенциально приводя к потере информации в «насыщенных» поддиапазонах.

Исходя из вышеперечисленных особенностей формирования кластеров, ядро алгоритма кластеризации при выделении k кластеров имеет следующий вид:

- 1) определение глобального максимума гистограммы h_{max} и назначение его центром первого кластера c_1 :

$$h_{max} = \max h[l], \quad l_{min} \leq l \leq l_{max}, \quad (9)$$

где l_{min} и l_{max} – минимальное и максимальное значение индекса интенсивности, для которого $h[l] \neq 0$;

- 2) поиск локальных максимумов, превышающих определенный порог

$$P = \{i \in [l_{min}, \dots, l_{max}] \mid h[i] > h[i - 1], h[i] > h[i + 1], h[i] > \tau h_{max}\}, \quad (10)$$

где P – множество индексов локальных максимумов,

τ – множитель для определения порогового значения высоты пика относительно глобального максимума;

- 3) определение значимости пиков $prom[i]$ – насколько сильно они выделяются относительно соседних значений – и сортировка по этой величине (чем больше значимость, тем более важен этот локальный максимум)

$$prom[i] = h[i] - \max\{h[i - 1], h[i + 1]\}; \quad (11)$$

- 4) назначение остальных центроидов $k - 1$ самыми значимыми пиками, расположенными дальше минимально допустимого расстояния d_{min} от уже отобранных центроидов.

Такой алгоритм позволяет определить самые важные центроиды, которые достаточно распределены по гистограмме, что позволяет покрыть весь ее диапазон.

2.1.2. Определение недостающих центров кластеров. Допустим, на первом этапе было определено r , $r < k$ центроидов, и остается определить центры $m = k - r$ кластеров. Для этого целесообразно выбирать значения яркости, которые часто встречаются на гистограмме и максимально удалены от уже отобранных центроидов. В соответствии с этим вводится оценочная функция $\Phi[l]$:

$$\Phi[l] = h[l] * \delta[l], \quad (12)$$

где $h[l]$ – число пикселей яркостью l ,

$\delta[l] = \min_{c \in C} |l - c|$ – минимальное расстояние до уже выбранных центроидов,

где C – множество отобранных центроидов.

Таким образом итеративно подбирается m центроидов, для каждого из которых оценочная функция $\Phi[l]$ максимальна.

2.1.3. Предварительная обработка гистограммы. Учитывая, что радиолокационные изображения, как правило, содержат спекл-шум и различные артефакты, гистограмму целесообразно подвергнуть сглаживанию [66, 97]. Для этого можно использовать универсальное сглаживание на основе свертки с Гауссовым ядром $g_0[t]$ [98], вычисляемым по формуле

$$g_0[t] = \exp\left(-\frac{t^2}{2\sigma^2}\right), t \in \{-r, \dots, r\}, \quad (13)$$

где t – дискретное смещение от центра окна сглаживания,

r – радиус окна сглаживания (ширина ядра),

$\sigma = r/2$ – половина радиуса окна сглаживания.

Далее производится нормирование

$$g[t] = \frac{g_0[t]}{\sum_{j=-r}^r g_0[j]} \quad (14)$$

так, чтобы $\sum_{t=-r}^r g[t] = 1$, а затем – свертка гистограммы с нормированным ядром:

$$s[l] = \sum_{t=-r}^r h[l + t]g[t], \quad (15)$$

где $s[l]$ – сглаженная гистограмма изображения.

Следует отметить, что сглаживание окна по формуле 15 проводится до начала поиска центров кластеров по гистограмме. Соответственно, формулы 9–12, составляющие основу алгоритма, остаются актуальными, только в них производится замена обычной гистограммы на сглаженную $h[l] \rightarrow s[l]$.

2.1.4. Улучшение положений центров кластеров. Поскольку пики на сглаженной гистограмме могут не совпадать с истинными центрами кластеров в исходных данных, необходимо произвести уточнение положений центроидов,

сместив их в сторону локального центра масс. Для этого в локальной окрестности центра кластера рассчитывается центр масс и в него перемещается положение центроида:

$$\hat{c}_i = (\sum_{l=c_i-\frac{d_{min}}{2}}^{c_i+\frac{d_{min}}{2}} l * h[l]) / (\sum_{l=c_i-\frac{d_{min}}{2}}^{c_i+\frac{d_{min}}{2}} h[l]), \quad (16)$$

где \hat{c}_i – уточненное положение кластера,

$h[l]$ – исходная (несглаженная) гистограмма.

Уточнение таким образом положения центроида минимизирует взвешенную сумму квадратов отклонений [99].

2.1.5. Алгоритм адаптивной кластеризации по максимумам гистограммы. Разработанный алгоритм можно назвать адаптивной кластеризацией по максимумам гистограммы (АКМГ), что отражает его основные особенности – хорошее выделение максимумов и адаптацию под другие формы гистограмм. При этом АКМГ является детерминированным алгоритмом, что соответствует одному из главных требований. Учитывая все описанные действия, структура АКМГ имеет следующий вид:

- 1) задание начальных параметров – числа формируемых кластеров k , ширины ядра Гаусса r , защитного интервала между центроидами d_{min} , минимального уровня фиксируемых максимумов τ ;
- 2) вычисление гистограммы изображения $h[l]$;
- 3) определение l_{min} и l_{max} путем отсечения нулевых значений по краям для оптимизации последующих вычислений;
- 4) вычисление сглаженной гистограммы $s[l]$;
- 5) определение глобального максимума s_{max} и присвоение его индекса центру первого кластера;
- 6) поиск локальных максимумов P , удовлетворяющих ограничению по уровню;
- 7) определение значимости пиков $prom[i]$ и сортировка их по убыванию;

- 8) назначение оставшимися центроидами $k - 1$ самых значимых пиков при условии их расположения как минимум на расстоянии d_{min} друг от друга;
- 9) при наличии незаполненных центров кластеров их определение на основе плотностно-дистанционной оценки $\Phi[l]$;
- 10) уточнение положений центроидов \hat{c}_l с помощью взвешенного среднего;
- 11) сортировка полученных центров кластеров по возрастанию.

2.1.6. Оценка быстродействия и точности формирования кластеров

АКМГ. Для оценки точности кластеризации, осуществляемой с помощью АКМГ, без привязки к конкретным исходным данным и целевым результатам, можно использовать метрику WCSS (Within-Cluster Sum of Squares) [73, 100], которая измеряет сумму квадратов расстояний объектов до центров их кластеров:

$$WCSS = \sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2, \quad (17)$$

где K – число кластеров,

C_k – множество точек, принадлежащих кластеру k ,

x_i – яркость пикселя,

μ_k – центр кластера k .

Чем меньше значение WCSS, тем более компактно распределены кластеры и тем лучше оцениваемая точность кластеризации.

В качестве алгоритмов, с которыми будет сравниваться АКМГ, выбраны оптимизация Дженкса [47] и K-Means++ [65] как точные, но ресурсозатратные, а также равномерный метод [74] как один из самых простых и быстрых.

Сравнение проводилось на специально созданных псевдослучайных гистограммах размером $L = 256$ и $L = 512$. Примеры таких гистограмм (пиковая и гладкая) показаны на рисунках 9 и 10.

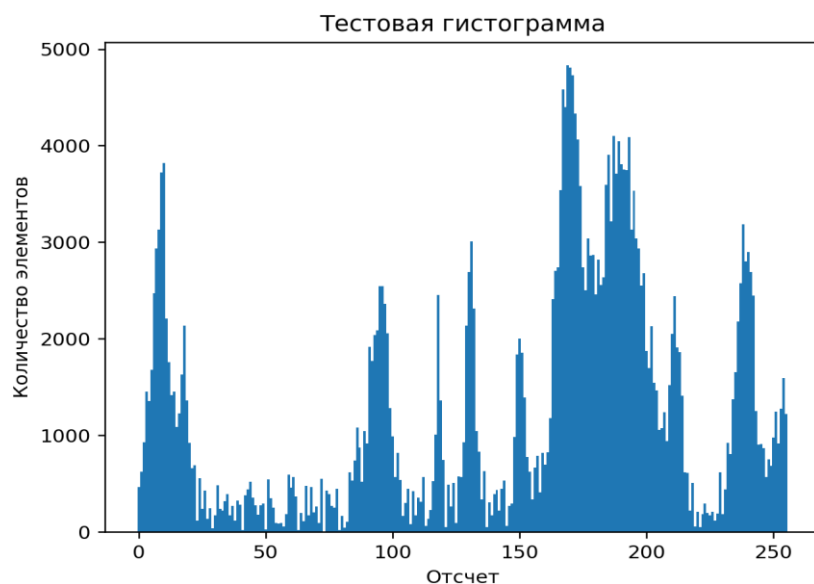


Рисунок 9 – Пример тестовой гистограммы с большим числом пиков

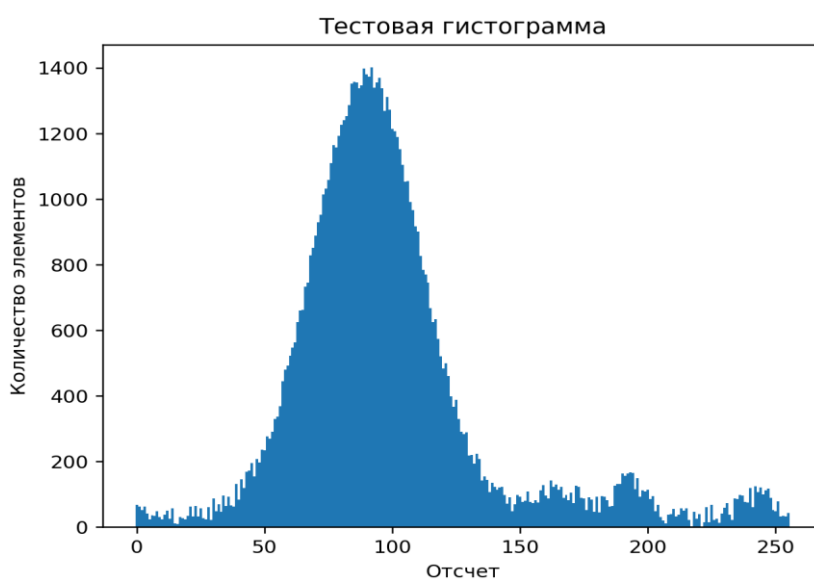


Рисунок 10 – Пример тестовой гистограммы с одним ярко выраженным пиком

Для указанных гистограмм в таблицах 2–5 приведены результаты замеров времени, а на рисунках 11–14 показаны графики зависимости WCSS алгоритмов от числа формируемых кластеров.

Таблица 2 – Оценка времени выполнения алгоритмов кластеризации для пиковой гистограммы при $L = 256$

Число кластеров	АКМГ (мс)	Равномерный (мс)	К-means++ (мс)	JNB (мс)
4	6,68	0,07	1036,30	378603,43
5	7,22	0,07	1295,00	402353,93
6	6,69	0,05	1310,35	494903,92
7	7,30	0,09	1274,00	580763,92
8	11,69	0,09	2154,02	612065,90

Таблица 3 – Оценка времени выполнения алгоритмов кластеризации для пиковой гистограммы при $L = 512$

Число кластеров	АКМГ (мс)	Равномерный (мс)	К-means++ (мс)	JNB (мс)
4	7,92	0,04	852,21	572193,85
5	8,16	0,06	1277,84	599505,08
6	6,61	0,10	1320,39	729917,83
7	7,95	0,07	1393,31	859420,23
8	8,13	0,06	1816,05	973910,13

Таблица 4 – Оценка времени выполнения алгоритмов кластеризации для гладкой гистограммы при $L = 256$

Число кластеров	АКМГ (мс)	Равномерный (мс)	К-means++ (мс)	JNB (мс)
4	5,02	0,06	888,51	298661,88
5	6,42	0,04	896,43	349771,38
6	7,82	0,09	1136,73	467480,43
7	8,87	0,08	1487,24	510850,87
8	7,48	0,05	1829,69	598371,27

Таблица 5 – Оценка времени выполнения алгоритмов кластеризации для гладкой гистограммы при $L = 512$

Число кластеров	АКМГ (мс)	Равномерный (мс)	К-means++ (мс)	JNB (мс)
4	4,84	0,05	816,48	454680,91
5	10,30	0,13	1311,06	388146,10
6	6,75	0,04	1217,45	500145,78
7	8,77	0,09	1976,98	570190,16
8	6,86	0,07	2041,90	741372,64




Рисунок 11 – Сравнение WCSS алгоритмов кластеризации для пиковой гистограммы при $L = 256$

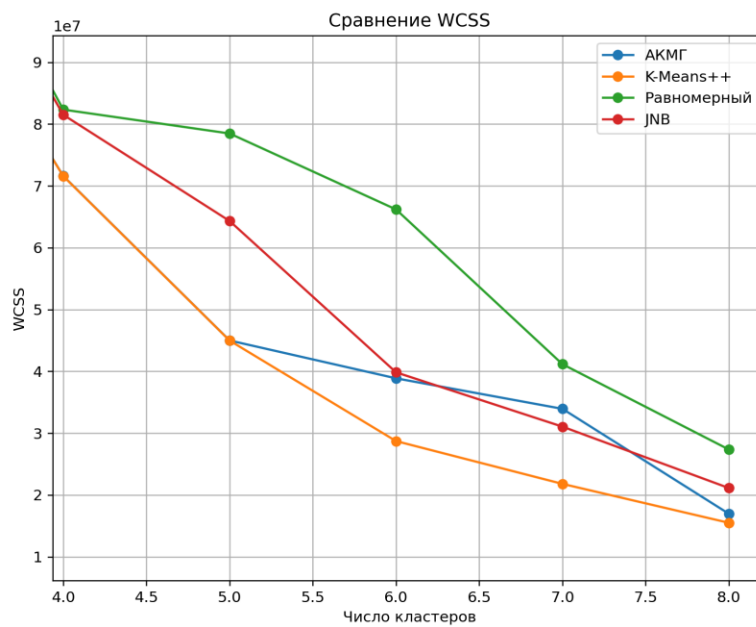


Рисунок 12 – Сравнение WCSS алгоритмов кластеризации для пиковой гистограммы при $L = 512$

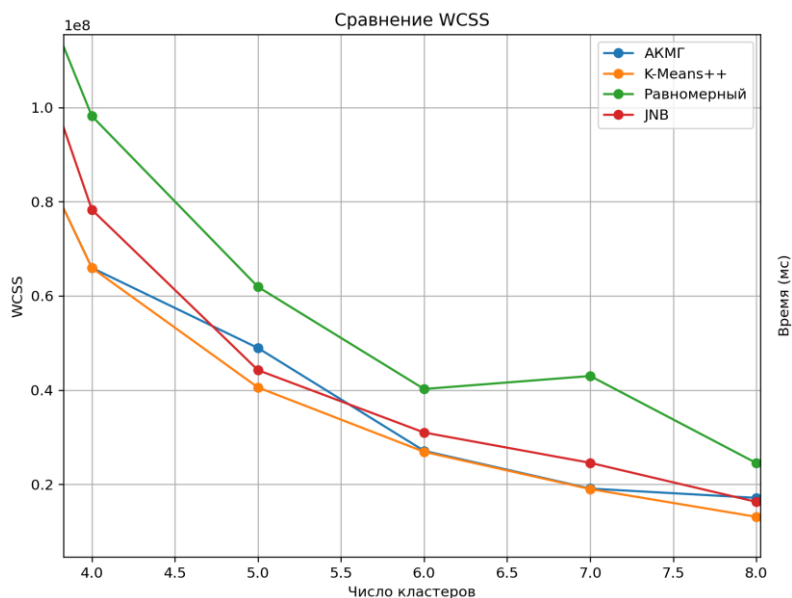


Рисунок 13 – Сравнение WCSS алгоритмов кластеризации для гладкой гистограммы при $L = 256$




Рисунок 14 – Сравнение WCSS алгоритмов кластеризации для гладкой гистограммы при $L = 512$

Полученные экспериментальные результаты позволяют подтвердить соответствие алгоритма АКМГ остальным требованиям. Среди сравниваемых алгоритмов АКМГ лишь немного уступает по WCSS самому точному K-Means++, в

то время как время выполнения в 100–250 раз меньше. Таким образом, разработанный алгоритм АКМГ является детерминированным, обладает точностью кластеризации, сопоставимой с K-Means++, и значительно лучшим быстродействием.

2.2 Применение алгоритма поляриметрической классификации Клода-Потье с использованием классификатора Уишарта для выполнения сегментации изображений на классы водной поверхности и суши

2.2.1. Описание проводимых экспериментов. В качестве экспериментальных данных в главах 2 и 3 использовались натурные полнополяризационные радиолокационные изображения (в дальнейшем экспериментальные изображения), полученные космическим аппаратом «RadarSat-2». В рамках указанных глав будет использоваться их условная нумерация – «№1», «№2» и «№3». Представление данных изображений в псевдоцвете приведено на рисунках 15–17.



Рисунок 15 – Изображение №1 в псевдоцвете




Рисунок 16 – Изображение №2 в псевдоцвете




Рисунок 17 – Изображение №3 в псевдоцвете

Для оценки достоверности алгоритмов сегментации для каждого из экспериментальных изображений были сформированы эталонные результаты сегментации (в дальнейшем, маски), в которых пиксели были вручную отнесены к одному из двух целевых классов. Погрешность при формировании масок не превышает 10^{-4} .

Сформированные маски изображений приведены на рисунках 18–20. Белым цветом обозначен класс водной поверхности, черным – класс суши.



Рисунок 18 – Эталонная маска изображения №1




Рисунок 19 – Эталонная маска изображения №2



Рисунок 20 – Эталонная маска изображения №3

Достоверность сегментации рассчитывалась по формуле:

$$Acc = (Acc_B + Acc_C)/2 \quad (18)$$

где Acc_B и Acc_C – достоверность сегментации воды и суши соответственно, рассчитываемые как

$$Acc_B = P_B/N_B, \quad (19)$$

$$Acc_C = P_C/N_C, \quad (20)$$

где P_B и P_C – число правильно классифицированных пикселей воды и суши, определенное с помощью маски изображения,

N_B и N_C – количество пикселей воды и суши на маске изображения.

2.2.2. Описание алгоритма действий. В п. 1.4.6 на основании анализа алгоритмов поляриметрической классификации был обоснован выбор алгоритма Клода-Потье с использованием классификатора Уишарта как наиболее подходящего для целевой сегментации изображения благодаря наименьшему числу ошибок.

Согласно границам зон, выделенным Клодом и Потье и приведенным на рисунке 5, водные объекты попадают в зону 3 (вода со слабым волнением) и зону 6 (вода с сильным волнением). Таким образом, если объединить пиксели из зон 3 и 6 в одну группу, а из остальных – в другую, то можно выполнить целевую сегментацию.

2.2.3. Результаты экспериментов. В таблице 6 приведены результаты оценки достоверности сегментации на основе поляриметрической классификации Клода-Потье для экспериментальных изображений с окнами обработки разного размера.

Таблица 6 – Достоверность сегментации на основе поляриметрической классификации Клода-Потье при разных размерах окна обработки

№	Размер окна	Acc_b	Acc_c	Acc
1	1x1	0,9345	0,9625	0,9485
	3x3	0,6507	0,9827	0,8172
	5x5	0,9651	0,9964	0,9808
	7x7	0,9632	0,9975	0,9804
	9x9	0,9596	0,9982	0,9790
	11x11	0,9554	0,9988	0,9772
	13x13	0,9512	0,9991	0,9752
	15x15	0,9467	0,9994	0,9731
	17x17	0,9487	0,9992	0,9740
	19x19	0,9451	0,9994	0,9723
	21x21	0,9308	0,9998	0,9654
	23x23	0,9268	0,9998	0,9634
25x25	0,9238	0,9998	0,9619	
2	1x1	0,9301	0,8692	0,8997
	3x3	0,0623	0,5967	0,3295
	5x5	0,3075	0,7502	0,5289
	7x7	0,7354	0,8087	0,7721
	9x9	0,7943	0,8167	0,8055
	11x11	0,9217	0,9192	0,9205
	13x13	0,9123	0,9251	0,9187
	15x15	0,9031	0,9304	0,9168
	17x17	0,8943	0,9349	0,9146
	19x19	0,8857	0,9384	0,9121
	21x21	0,8732	0,9463	0,9098
	23x23	0,8647	0,9488	0,9068
25x25	0,8568	0,9505	0,9037	

№	Размер окна	Acc_B	Acc_C	Acc
3	1x1	0,0097	0,6387	0,3242
	3x3	0,9639	0,8519	0,9079
	5x5	0,9610	0,8619	0,9115
	7x7	0,9610	0,8586	0,9098
	9x9	0,9630	0,8192	0,8911
	11x11	0,9772	0,9499	0,9636
	13x13	0,9762	0,9527	0,9645
	15x15	0,9755	0,9536	0,9646
	17x17	0,9748	0,9538	0,9643
	19x19	0,9662	0,8020	0,8841
	21x21	0,9739	0,9537	0,9638
	23x23	0,9750	0,8144	0,8947
	25x25	0,9647	0,8036	0,8842

Полученные результаты свидетельствуют о сильном влиянии размера окна обработки на достоверность сегментации, поэтому необходимо определить универсальное значение для дальнейшего использования. Так как для каждого из экспериментальных изображений результаты сильно разнятся, введем ограничение: достоверность формирования каждого класса в отдельности должна быть не меньше 0,90. В этом случае обеспечивается высокая достоверность сегментации как каждого класса в отдельности, так и всего изображения в целом.

Учитывая введенное ограничение, можно определить размер окна обработки. Согласно таблице 6 меньше всего подходящих результатов сегментации у изображения №2 – с размерами окон 11x11, 13x13 и 15x15, – при этом достоверность сегментации других изображений также удовлетворительна. Таким образом, лучший размер окна обработки можно определить по наибольшей средней достоверности сегментации по всем трем изображениям. Результаты расчетов приведены в таблице 7.

Таблица 7 – Результаты расчета средней достоверности сегментации для выбранных размеров окна обработки

Размер окна	Изображение №1	Изображение №2	Изображение №3	Средняя достоверность
11x11	0,9772	0,9205	0,9636	0,9538

Размер окна	Изображение №1	Изображение №2	Изображение №3	Средняя достоверность
13x13	0,9752	0,9187	0,9645	0,9528
15x15	0,9731	0,9168	0,9646	0,9515

Судя по полученным результатам, размер окна обработки, обеспечивающий наибольшую среднюю достоверность сегментации с учетом введенных ограничений, – 11x11.

2.2.4. Результаты сегментации на основе поляриметрической классификации. Примеры изображений с результатами сегментации на основе поляриметрической классификации Клода-Потье с использованием классификатора Уишарта приведены на рисунках 21–23. Основные ошибки определения пикселей воды в класс суши связаны с большим размером окна обработки, из-за чего некоторые узкие водные участки «поглощаются» сушей. Ошибки обратной классификации преимущественно вызваны наличием гладких структур на поверхности (асфальтированные дороги, горные склоны (в том числе теневые) и т.д.), которые отражают малую часть сигнала обратно подобно воде. Тем не менее, и вычисленные значения достоверности, и визуальное восприятие полученных изображений позволяют подтвердить возможность выполнения сегментации радиолокационных изображений с помощью поляриметрической классификации Клода-Потье.



Рисунок 21 – Результат сегментации изображения №1 на основе поляриметрической классификации Клода-Потье с использованием классификатора Уишарта




Рисунок 22 – Результат сегментации изображения №2 на основе поляриметрической классификации Клода-Потье с использованием классификатора Уишарта




Рисунок 23 – Результат сегментации изображения №3 на основе поляриметрической классификации Клода-Потье с использованием классификатора Уишарта

2.3 Оценка достоверности сегментации необработанных радиолокационных изображений на классы водной поверхности и суши

2.3.1. Метод эксперимента. Оценка достоверности сегментации радиолокационных изображений без предварительной обработки выполнялась экспериментальным образом методом перебора. Каждое значение интенсивности пикселя назначалось граничным, разделяющим классы водной поверхности и суши, после чего определялась достоверность сегментации. По итогам эксперимента фиксировалось максимальное значение достоверности.

2.3.2. Результаты эксперимента. Оценки максимальной достоверности сегментации необработанных радиолокационных изображений приведены в таблице 8. Примеры полученных изображений представлены на рисунках 24 и 25.

Таблица 8 – Результаты сегментации, выполненной по яркости пикселей

№ изобр.	Поляризация	Acc_B	Acc_C	Acc
1	VV	0,8274	0,6872	0,7573
	VH	0,9315	0,8352	0,8834
	HH	0,8952	0,7801	0,8377
	HV	0,9326	0,8339	0,8832
2	VV	0,8563	0,7605	0,8084
	VH	0,8869	0,7774	0,8321
	HH	0,8647	0,7806	0,8227
	HV	0,8819	0,7840	0,8330




Рисунок 24 – Сегментация необработанного изображения №1
(поляризация HH)



Рисунок 25 – Сегментация необработанного изображения №2
(поляризация *VH*)

Полученные сегментированные изображения содержат высокую зашумленность и, как следствие, большое количество ложных классификаций пикселей воды и суши. Приведенные оценки достоверности являются неудовлетворительными, что подтверждает необходимость выполнения предварительной обработки изображений.

2.4 Отбор текстурных признаков Харалика для применения в алгоритме сегментации радиолокационных изображений

2.4.1. Анализируемые текстурные признаки. Для выполнения предварительной обработки радиолокационных изображений в виде текстурного анализа по Харалику сперва необходимо отобрать текстурные признаки, позволяющие выполнить сегментацию с наибольшей достоверностью. В п. 1.5.4 перечислены текстурные признаки, которые рассчитываются с помощью GLCM (формула 7). При этом три последних признака являются близкими по физическому смыслу с

признаком корреляции, поэтому их пригодность для выполнения сегментации радиолокационных изображений с целью определения водной поверхности и суши можно оценить по пригодности признака корреляции. Вследствие этого будут проанализированы следующие текстурные признаки:

1) второй угловой момент (энергия):

$$f_1 = \sum_i \sum_j \{p(i, j)\}^2,$$

где $p(i, j)$ – нормализованная GLCM;

2) контраст:

$$f_2 = \sum_i \sum_j (i - j)^2 p(i, j);$$

3) корреляция:

$$f_3 = \frac{\sum_i \sum_j (i - \mu_x)(j - \mu_y) p(i, j)}{\sigma_x \sigma_y},$$

где μ_x, μ_y – среднее арифметическое, σ_x, σ_y – среднее квадратическое отклонение (СКО);

4) дисперсия:

$$f_4 = \sum_i \sum_j (i - \mu)^2 p(i, j),$$

где μ – глобальное среднее матрицы;

5) обратный дифференциальный момент (гомогенность):

$$f_5 = \sum_i \sum_j \frac{p(i, j)}{1 + (i - j)^2};$$

6) средняя сумма:

$$f_6 = \sum_{k=2}^{2L} k p_{x+y}(k),$$

где $p_{x+y}(k) = \sum_i \sum_j p(i, j) \delta(i + j - k)$, $k = 2, 3, \dots, 2L$ – вероятность суммы $i + j = k$, где δ – функция Кронекера;

7) дисперсия сумм:

$$f_7 = \sum_{k=2}^{2L} (k - f_6)^2 p_{x+y}(k);$$

8) энтропия сумм:

$$f_8 = - \sum_{k=2}^{2L} p_{x+y}(k) \log(p_{x+y}(k));$$

9) энтропия:

$$f_9 = - \sum_i \sum_j p(i, j) \log(p(i, j));$$

10) дисперсия разностей:

$$f_{10} = \sum_d d^2 p_{(x-y)}(d);$$

11) энтропия разностей:

$$f_{11} = - \sum_d p_{x-y}(d) \log(p_{x-y}(d)).$$

2.4.2. Метод эксперимента и результаты. Оценка максимальной достоверности сегментации, усредненная по четырем каналам, которой можно достичь при использовании указанных текстурных признаков, выполнялась аналогично п. 2.3.1. Дополнительно замерялось время вычисления каждого текстурного признака (суммарно по всем каналам). Результаты приведены в таблице 9.

Таблица 9 – Результаты оценки максимальной достоверности сегментации текстурных признаков Харалика

Текстурный признак	№ изобр.	Acc _в	Acc _с	Acc	t, с
Второй угловой момент	1	0,9790	0,9824	0,9807	131,77
	2	0,9449	0,9569	0,9509	143,06
Контраст	1	0,9546	0,9888	0,9717	154,63
	2	0,8557	0,9608	0,9082	178,78
Корреляция	1	0,8501	0,8731	0,8616	145,33
	2	0,6250	0,9068	0,7659	157,50
Дисперсия	1	0,9441	0,9915	0,9678	132,74
	2	0,8144	0,9708	0,8926	136,89
Обратный дифференциальный момент	1	0,9784	0,9803	0,9793	136,70
	2	0,9434	0,9524	0,9479	137,80
Средняя сумма	1	0,9695	0,9857	0,9776	162,96
	2	0,9099	0,9526	0,9313	164,38
Дисперсия сумм	1	0,9411	0,9914	0,9662	181,28
	2	0,8022	0,9734	0,8878	189,42

Текстурный признак	№ изобр.	Acc_B	Acc_C	Acc	t, c
Энтропия сумм	1	0,9581	0,9896	0,9738	569,20
	2	0,8739	0,9657	0,9198	555,52
Энтропия	1	0,9681	0,9872	0,9777	520,28
	2	0,9105	0,9597	0,9351	531,92
Дисперсия разностей	1	0,9462	0,9910	0,9686	177,78
	2	0,8203	0,9710	0,8957	176,00
Энтропия разностей	1	0,9618	0,9885	0,9752	534,13
	2	0,8898	0,9588	0,9243	515,19

Анализируя полученные результаты можно заметить, что наибольшую возможную достоверность сегментации показали следующие текстурные признаки (в порядке убывания): второй угловой момент, обратный дифференциальный момент и энтропия. При этом время вычисления энтропии приблизительно в три раза превышает время вычисления других признаков, поэтому для задачи оперативной сегментации ее использовать нецелесообразно. Данные признаки будут использоваться в дальнейших вычислениях, однако при оценке быстродействия энтропия будет игнорироваться.

Также отмечено, что у разных текстурных признаков отличаются абсолютные и относительные диапазоны значений, характерные для формируемых классов. Помимо свойств самих объектов, влияние оказывают размер окна обработки и число уровней квантования. Таким образом, для фиксированных значений этих двух параметров необходимо определить диапазоны, характерные для классов водной поверхности и суши, при вычислении каждого отобранного признака.

2.5 Алгоритм сегментации радиолокационных изображений для определения водной поверхности и суши

2.5.1. Применение АКМГ к результатам текстурного анализа. Разработанный алгоритм кластеризации устраняет главный недостаток алгоритмов на базе k -средних – возможность получения разных результатов сегментации при

повторной обработке изображений. Далее необходимо оценить достоверность сегментации, получаемую при кластеризации результатов текстурного анализа с помощью АКМГ и сравнить ее со значениями, получаемыми при кластеризации с помощью K-Means++. Указанные действия выполнялись на экспериментальных изображениях и содержали следующие шаги:

- 1) кластеризация результатов текстурного анализа каждого канала (с поляризациями VV , VH , HH , HV) экспериментального изображения с помощью АКМГ (число формируемых кластеров $k = 8$);
- 2) поочередный перебор всех возможных комбинаций объединения пикселей кластеров в классы водной поверхности и суши с оценкой достоверности сегментации;
- 3) сравнение лучшего значения достоверности с достоверностью сегментации, выполненной на основе K-Means++ ($k = 8$).

Данные шаги выполнялись для каждого экспериментального изображения и для каждого отобранного текстурного признака.

2.5.2. Задание условий экспериментов. Число формируемых кластеров было выбрано не случайным образом, а на основе следующих размышлений. Оно не должно быть слишком большим, так как приведет к увеличению временных затрат, а также усложнит распределение центроидов с соблюдением минимального расстояния между ними для относительно узких гистограмм. В то же время это число не должно быть слишком малым, потому что в таком случае повышается вероятность некорректной классификации пикселей. Так как в разделе 2.2 было показано, что сегментация на основе поляриметрической классификации Клода-Потье может быть выполнена с достаточно высокой достоверностью (более 0,90), а в ней выделяется 8 классов, данное значение, удовлетворяющее поставленным ранее условиям, можно использовать в качестве числа формируемых кластеров. Аналогично размер окна обработки был выбран 11×11 . Также использовались 256 уровней квантования для расчета текстурных признаков, так

как данное значение позволяет достаточно хорошо передать вариации в структуре пикселей изображения.

2.5.3. Результаты экспериментальных исследований. Ниже в таблицах 10–12 приведены значения достоверности сегментации, получаемые с помощью кластеризации на основе АКМГ и K-Means++ для каждого исследуемого текстурного признака и для каждого экспериментального изображения. Кроме того, для энергии и гомогенности фиксировалось время выполнения текстурного анализа и определения кластеров.

Таблица 10 – Сравнение алгоритмов сегментации при расчете текстурного признака энергии

Изображение		Acc_{AKMG}	Acc_{KM}	t_{TA}, c	t_{AKMG}, mc	t_{KM}, c
1	Канал VV	0,9700	0,9770	31,37	482	24,04
	Канал VH	0,9802	0,9738	30,97	477	24,28
	Канал HH	0,9846	0,9759	31,29	481	28,06
	Канал HV	0,9802	0,9737	31,25	480	21,04
	Средняя	0,9788	0,9751	31,22	480	24,36
2	Канал VV	0,9226	0,7061	32,23	505	39,50
	Канал VH	0,9301	0,9808	32,07	498	36,09
	Канал HH	0,9213	0,7426	32,14	501	42,00
	Канал HV	0,9278	0,9810	32,48	508	32,22
	Средняя	0,9255	0,8526	32,23	503	37,45
3	Канал VV	0,9848	0,8360	28,88	346	16,94
	Канал VH	0,9741	0,9234	28,94	344	14,86
	Канал HH	0,9864	0,8214	27,72	347	7,36
	Канал HV	0,9738	0,9245	27,57	351	23,68
	Средняя	0,9798	0,8763	28,28	347	15,71

Таблица 11 – Сравнение алгоритмов сегментации при расчете текстурного признака гомогенности

Изображение		Acc_{AKMG}	Acc_{KM}	t_{TA}, c	t_{AKMG}, mc	t_{KM}, c
1	Канал VV	0,9639	0,9719	40,26	478	24,48
	Канал VH	0,9794	0,9749	42,18	483	35,82
	Канал HH	0,9855	0,9856	40,89	479	16,11
	Канал HV	0,9798	0,9751	40,81	480	31,40
	Средняя	0,9772	0,9769	41,04	480	26,95
2	Канал VV	0,9469	0,9392	41,11	544	34,89
	Канал VH	0,9324	0,9496	44,96	545	19,48
	Канал HH	0,9430	0,9293	43,10	544	36,00

Изображение		Acc_{AKMG}	Acc_{KM}	t_{TA}, c	t_{AKMG}, mc	t_{KM}, c
	Канал <i>HV</i>	0,9342	0,9502	43,77	551	21,73
	Средняя	0,9391	0,9421	43,24	546	28,03
3	Канал <i>VV</i>	0,9833	0,9837	36,97	505	22,56
	Канал <i>VH</i>	0,9807	0,9826	37,33	506	29,67
	Канал <i>HH</i>	0,9824	0,9824	35,71	509	31,32
	Канал <i>HV</i>	0,9805	0,9826	37,05	508	22,43
	Средняя	0,9817	0,9828	36,77	507	26,50

Таблица 12 – Сравнение алгоритмов сегментации при расчете текстурного признака энтропии

Изображение		Acc_{AKMG}	Acc_{KM}
1	Канал <i>VV</i>	0,9696	0,9717
	Канал <i>VH</i>	0,9768	0,9727
	Канал <i>HH</i>	0,9819	0,9782
	Канал <i>HV</i>	0,9770	0,9726
	Средняя	0,9763	0,9738
2	Канал <i>VV</i>	0,9298	0,9352
	Канал <i>VH</i>	0,9096	0,9190
	Канал <i>HH</i>	0,9233	0,9297
	Канал <i>HV</i>	0,9095	0,9329
	Средняя	0,9181	0,9292
3	Канал <i>VV</i>	0,9824	0,9859
	Канал <i>VH</i>	0,9798	0,9812
	Канал <i>HH</i>	0,9797	0,9837
	Канал <i>HV</i>	0,9797	0,9812
	Средняя	0,9804	0,9830

Полученные результаты позволяют сделать несколько выводов. Во-первых, применение АКМГ более чем в половине случаев позволило достичь большей достоверности сегментации, по сравнению с K-Means++. При этом средние значения по всем экспериментам составили 0,9619 против 0,9435, что означает увеличение достоверности на 1,84 %. Во-вторых, помимо того, что АКМГ является детерминированным алгоритмом, время его расчета с учетом распределения пикселей изображения по кластерам (в п. 2.1.6 сравнивалось только время вычисления кластеров) в среднем в 45–60 раз меньше, чем у K-Means++, что позволяет увеличить быстродействие на 35–50 %.

Таким образом, применение АКМГ для кластеризации значений текстурных признаков позволяет не только обеспечить повторяемость результатов сегментации, но и уменьшить время вычислений при в среднем большей достоверности.

2.5.4. Определение границы между классами водной поверхности и суши. Далее, опираясь на полученные результаты наилучшей сегментации, необходимо определить диапазоны значений текстурных признаков, соответствующие каждому классу. С этой целью для каждого текстурного признака необходимо:

- 1) зафиксировать центры кластеров;
- 2) нормировать значения центроидов для каждого канала;
- 3) определить диапазон, внутри которого находится граница между классами, и извлечь ее значение.

В таблицах 13–15 приведены значения полученных центров кластеров после нормирования для каждого исследуемого текстурного признака (полужирным шрифтом выделен центроид, после которого начинается другой класс).

Таблица 13 – Нормированные центры кластеров для текстурного признака энергии

№ изобр.	Канал	c_0	c_1	c_2	c_3	c_4	c_5	c_6	c_7
1	VV	0,012	0,015	0,020	0,024	0,064	0,086	0,108	0,151
	VH	0,038	0,060	0,074	0,088	0,117	0,559	0,586	0,614
	HH	0,008	0,010	0,012	0,016	0,020	0,124	0,200	0,277
	HV	0,037	0,060	0,075	0,089	0,121	0,567	0,596	0,625
2	VV	0,011	0,013	0,015	0,018	0,021	0,028	0,036	0,181
	VH	0,040	0,051	0,062	0,074	0,086	0,118	0,151	0,617
	HH	0,007	0,009	0,011	0,013	0,015	0,018	0,035	0,278
	HV	0,040	0,050	0,060	0,072	0,084	0,114	0,144	0,608
3	VV	0,038	0,149	0,338	0,447	0,566	0,774	0,894	1,000
	VH	0,009	0,022	0,042	0,055	0,076	0,575	0,641	0,708
	HH	0,025	0,101	0,174	0,273	0,405	0,545	0,633	0,710
	HV	0,009	0,022	0,042	0,055	0,074	0,574	0,644	0,705

Таблица 14 – Нормированные центры кластеров для текстурного признака гомогенности

№ изобр.	Канал	c_0	c_1	c_2	c_3	c_4	c_5	c_6	c_7
1	VV	0,198	0,231	0,266	0,302	0,451	0,544	0,607	0,708
	VH	0,330	0,414	0,485	0,555	0,876	0,888	0,897	0,906
	HH	0,174	0,216	0,265	0,316	0,578	0,660	0,742	0,836
	HV	0,337	0,416	0,491	0,567	0,878	0,890	0,898	0,907
2	VV	0,195	0,213	0,230	0,244	0,258	0,286	0,600	0,787
	VH	0,361	0,403	0,424	0,445	0,479	0,513	0,584	0,932
	HH	0,165	0,188	0,211	0,228	0,245	0,279	0,516	0,750
	HV	0,351	0,393	0,414	0,434	0,468	0,501	0,568	0,921
3	VV	0,077	0,093	0,109	0,117	0,127	0,145	0,179	0,558
	VH	0,063	0,080	0,089	0,099	0,117	0,154	0,229	0,843
	HH	0,065	0,079	0,085	0,092	0,099	0,107	0,122	0,635
	HV	0,066	0,075	0,084	0,102	0,120	0,156	0,227	0,840

Таблица 15 – Нормированные центры кластеров для текстурного признака энтропии

№ изобр.	Канал	c_0	c_1	c_2	c_3	c_4	c_5	c_6	c_7
1	VV	0,257	0,348	0,398	0,482	0,633	0,681	0,728	0,765
	VH	0,066	0,073	0,079	0,400	0,463	0,529	0,565	0,602
	HH	0,235	0,305	0,306	0,370	0,649	0,697	0,746	0,804
	HV	0,064	0,072	0,081	0,396	0,463	0,529	0,565	0,600
2	VV	0,300	0,324	0,666	0,698	0,715	0,731	0,757	0,784
	VH	0,041	0,365	0,453	0,481	0,508	0,526	0,544	0,580
	HH	0,219	0,551	0,682	0,723	0,743	0,763	0,791	0,820
	HV	0,039	0,392	0,458	0,485	0,513	0,529	0,545	0,579
3	VV	0,495	0,923	0,930	0,936	0,943	0,949	0,957	0,965
	VH	0,123	0,786	0,865	0,905	0,924	0,933	0,942	0,957
	HH	0,391	0,926	0,943	0,951	0,956	0,960	0,966	0,972
	HV	0,120	0,775	0,857	0,898	0,917	0,927	0,936	0,951

Относительно положения границы между центрами кластеров необходимо сделать важное уточнение. Для случаев, когда граничными являются крайние кластеры c_0 или c_6 , оценка достоверности исходит от расположения центра кластера, при этом невозможно гарантировать, что это расположение действительно находится в зоне другого класса. В связи с этим корректная интерпретация положения границы должна выглядеть следующим образом: если граничный кластер

- c_0 , то граница между классами находится от 0 до c_1 , а если граничный кластер
- c_6 , то граница между классами находится от c_6 до 1.

На основе полученных результатов можно сделать два вывода. Во-первых, у каналов *VV* и *HH* (с ко-поляризацией) диапазоны значений, в которых находится граница между классами, сильно отличаются от диапазонов каналов *VH* и *HV* (с кросс-поляризацией). Данное отличие связано с разными свойствами сигналов с ко-поляризацией и кросс-поляризацией, поэтому для классификации необходимо выделять два граничных значения. Во-вторых, получаемые диапазоны для каждой пары поляризаций не противоречат друг другу в пределах одного текстурного признака, на основании чего можно определить универсальные границы.

По имеющимся данным точное значение границы определить невозможно, так как полученные диапазоны достаточно широки, вследствие чего требуется проведение дополнительных исследований с новыми данными. В рамках данной работы за ее значение будет принята середина полученных диапазонов.

2.5.5. Значения границ между классами. В таблице 16 приведены значения межклассовых границ для текстурных признаков, рассчитанные по результатам экспериментов, приведенным в таблицах 13–15. В ней в столбцах « c_{min} » и « c_{max} » приведены нормированные значения центроидов, ограничивающие диапазон возможных значений границы снизу и сверху для соответствующей пары поляризаций, в столбце « c_{cp} » – середина этого диапазона, а в столбце «Соотношение яркостей» указано правило проведения классификации пикселей.

Таблица 16 – Значения границы между целевыми классами

Текстурный признак	Поляризация	c_{min}	c_{max}	c_{cp}	Соотношение яркостей
Энергия	<i>VV, HH</i>	0,028	0,036	0,032	$c_{воды} > c_{суши}$
	<i>VH, HV</i>	0,121	0,144	0,133	
Гомогенность	<i>VV, HH</i>	0,316	0,451	0,384	$c_{воды} > c_{суши}$
	<i>VH, HV</i>	0,584	0,840	0,712	

Текстурный признак	Поляризация	c_{min}	c_{max}	c_{cp}	Соотношение яркостей
Энтропия	VV, HH	0,551	0,633	0,592	$c_{воды} < c_{суши}$
	VH, HV	0,365	0,392	0,379	

2.5.6. Алгоритм сегментации радиолокационных изображений на основе детерминированного алгоритма кластеризации. Алгоритм сегментации (далее в работе этот алгоритм будет иметь условное обозначение «АС») принимает следующий вид:

- 1) выполнение текстурного анализа с окном обработки 11x11;
- 2) формирование восьми кластеров с помощью АКМГ;
- 3) нормирование центров кластеров в динамический диапазон изображения;
- 4) определение кластеров водной поверхности и суши на основе межклассовой границы и соотношения яркостей (Таблица 16);
- 5) классификация пикселей и формирование сегментированного изображения.

На рисунках 26–28 приведены результаты сегментации изображений (оценка достоверности сегментации приведена в таблицах 10–12) с помощью АС для некоторых комбинаций текстурного признака и вида поляризации. При сравнении с результатами, полученными на основе поляриметрической классификации (рисунки 21–23), можно сделать вывод, что ошибочная классификация пикселей суши в класс воды в целом уменьшилась, но плоские горные склоны и плато, а также часть асфальтированных дорог продолжают классифицироваться неправильно. В то же время, многие участки рек, которые были хорошо заметны при поляриметрической классификации, частично либо полностью пропали после использования АС.




Рисунок 26 – Результат сегментации на основе признака энтропии для канала *НV* изображения №1




Рисунок 27 – Результат сегментации на основе признака энергии для канала *НН* изображения №2



Рисунок 28 – Результат сегментации на основе признака гомогенности для канала VV изображения №3

2.5.7. Некоторые особенности сегментации на основе текстурного анализа. В ходе разработки алгоритма сегментации на основе текстурного анализа были обнаружены некоторые особенности, которые стоит отметить для понимания более полной картины и формирования направлений дальнейшего развития данного алгоритма.

Поскольку разные каналы изображений имеют разную ширину гистограммы, результаты их текстурного анализа также отличаются по получаемым диапазонам значений. В связи с этим и было принято решение использовать нормированные по динамическому диапазону канала центроиды для определения межклассовой границы. Тем не менее такой подход будет давать ложные результаты, если на сегментируемом изображении изначально присутствует только один класс. В связи с этим необходимо отметить, что предложенный алгоритм сегментации применим, только если исходное изображение содержит пиксели обоих классов.

Для того чтобы убрать вышеназванное условие, следует работать по абсолютным значениям текстурных признаков. Однако такой подход требует преодоления ряда трудностей, связанных с формированием исходного изображения. Результаты радиолокационной съемки при различных условиях могут отличаться по яркости, из-за чего абсолютные значения межклассовых границ могут не совпадать и таким образом приводить к разным результатам сегментации, хотя при определенных изменениях экспозиции изображения значения текстурных признаков могут остаться прежними.

Второй проблемой является спекл-шум. Приведенные в таблице 16 значения границ для признака энергии обозначают водную поверхность, начиная с 0,05 в абсолютной величине, при этом теоретически однородные поверхности, такие как вода со средним волнением или без него, должны иметь показатель энергии от 0,60–0,80 и выше. Такое несоответствие вызвано комбинацией двух факторов: наличием сильного спекл-шума и большим числом уровней квантования при расчете текстурного признака, что приводит к множеству различных комбинаций яркостей внутри GLCM, из-за чего значения признака получаются малыми. Уменьшение числа уровней квантования позволяет уменьшить неоднородность и расширить диапазон значений текстурного признака, однако при этом сильно снижается достоверность сегментации, поэтому данный подход недопустим. В результате единственным возможным на данный момент способом улучшения результатов является фильтрация спекл-шума, однако ее влияние на выходной результат требует дальнейших исследований. Данная проблема актуальна и для других текстурных признаков.

2.5.8. Анализ влияния статистических характеристик изображений на результаты текстурного анализа. Как было отмечено ранее, реальные диапазоны значений текстурных признаков не соответствуют теоретическим. Основной возможной причиной такого поведения является спекл-шум. В данном

пункте будут проведены исследования по подтверждению или опровержению этой теории.

Для того чтобы определить степень влияния спекл-шума на результаты текстурного анализа (на примере второго углового момента), необходимо рассчитать математическое ожидание (МО) и СКО для каждого канала (вида поляризации) анализируемых изображений, а также корреляцию [101] между пикселями. Результаты расчетов приведены в таблице 17. В ней в столбцах «ТА мин.» и «ТА макс.» указаны минимальное и максимальное полученные значения текстурного признака энергии соответственно (в масштабе от 0 до 10000).

Таблица 17 – Результаты расчета статистических параметров изображений

№ изобр.		МО	СКО	Корр.	ТА мин.	ТА макс.
1	VV	946,18	1059,17	0,58	11	3580
	VH	339,77	418,18	0,71	20	4544
	HH	981,53	1271,28	0,67	11	3530
	HV	341,62	420,30	0,71	20	4477
2	VV	1267,94	1329,06	0,58	12	3247
	VH	538,48	527,88	0,60	18	4101
	HH	1421,64	1567,00	0,61	11	3517
	HV	541,30	530,63	0,60	18	4161
3	VV	8820,01	5455,64	0,37	10	57
	VH	3748,33	2518,15	0,48	12	416
	HH	9053,08	5642,97	0,41	10	79
	HV	3740,07	2512,28	0,48	12	416

Полученные данные показывают некоторые тенденции. Во-первых, в пределах одного изображения статистические параметры каналов с ко-поляризацией схожи, равно как и у каналов с кросс-поляризацией. Во-вторых, для всех изображений справедливо, что МО и СКО у каналов с ко-поляризацией больше, чем у каналов с кросс-поляризацией. В-третьих, минимальное значение текстурного признака примерно одинаково для всех исходных данных, поэтому степень влияния спекл-шума на него по данной выборке изображений оценить затруднительно. В-четвертых, что самое главное, основная зависимость, которую можно

наблюдать, – это уменьшение максимального значения признака энергии при увеличении СКО.

Для дальнейшего анализа необходимо получить дополнительные данные. С этой целью выполнена фильтрация спекл-шума исходных изображений с помощью фильтра Фроста [88] (окном размером 3x3) и рассчитаны значения текстурного признака для обработанных изображений. Результаты приведены в таблице 18.

Таблица 18 – Результаты расчета статистических параметров изображений, обработанных с помощью фильтра Фроста

№ изобр.		МО	СКО	Корр.	ТА мин.	ТА макс.
1	VV	943,71	806,52	0,95	12	9415
	VH	338,96	333,11	0,97	22	9840
	HH	978,62	993,89	0,97	11	9260
	HV	340,82	334,71	0,97	23	9839
2	VV	1264,15	986,13	0,94	13	9621
	VH	537,13	393,59	0,95	21	9572
	HH	1416,99	1168,69	0,95	11	8870
	HV	539,94	395,49	0,95	21	9950
3	VV	8811,00	3279,76	0,91	11	638
	VH	3744,48	1653,91	0,95	15	2434
	HH	9043,36	3427,93	0,92	11	465
	HV	3736,27	1649,85	0,95	16	2716

Сравнивая данные до и после фильтрации, можно определить некоторые зависимости. Во-первых, фильтрация спекл-шума привела к небольшому приросту минимального значения энергии и к значительному увеличению максимального значения, которое на изображениях №1 и №2 приблизилось к возможному пределу, соответствующему идеально однородной области. Оба данных изменения были ожидаемы. Во-вторых, мат. ожидание после фильтрации осталось практически таким же, соответственно из влияющих переменных его можно исключить.

Основные изменения произошли с СКО и корреляцией. После фильтрации СКО значительно уменьшилось, а корреляция выросла практически до максимальных значений. Данные переменные независимы друг от друга, поэтому влияние каждой из них на максимальное значение текстурного признака подлежит изучению.

Преимущественно зависимость имеет следующий вид: чем больше СКО, тем меньше диапазон значений текстурного признака; чем больше корреляция, тем больше диапазон значений текстурного признака. При этом данные зависимости сложно оценить изолированно, так как в полученных статистических данных до фильтрации присутствуют исключения из данных правил. Например, у канала *НН* изображения №2 СКО больше, чем у канала *VV*, однако максимальное значение энергии выше; у канала *НН* изображения №1 корреляция выше, чем у канала *VV*, а максимальное значение энергии ниже; при этом, если добавить поправку на большее или меньшее значение другого параметра, результаты в целом сходятся.

Таким образом, если предположить, что другие факторы отсутствуют, влияние спекл-шума выражается в увеличении СКО и уменьшении корреляции между пикселями, а они в свою очередь приводят к уменьшению максимального значения текстурного признака. Поскольку каждый из этих параметров не влияет независимо, а имеет место их совокупность, воздействие указанных параметров на размер возможного диапазона значений текстурного признака носит мультипликативный характер.

Определение точной зависимости позволит при сегментации перейти от относительных значений текстурного признака к абсолютным путем использования корректирующих коэффициентов, учитывающих СКО и корреляцию конкретного изображения. Таким образом, отпадет необходимость в использовании алгоритма кластеризации и можно будет работать со значениями пикселей

напрямую. В настоящий момент имеющихся данных недостаточно для проведения глубокого анализа, поэтому в рамках текущей работы дополнительных исследований этой темы не будет.

Основные результаты

1. Разработан детерминированный алгоритм кластеризации АКМГ, отличающийся быстротой и близкой к K-Means++ точностью кластеризации по метрике WCSS.

2. Выполнена сегментация радиолокационных изображений на основе поляриметрической классификации Клода-Потье с использованием классификатора Уишарта. Показана высокая достоверность получаемых результатов.

3. Выполнена сегментация исходных радиолокационных изображений на классы водной поверхности и суши. Установлена высокая зашумленность результатов и, как следствие, неудовлетворительная достоверность сегментации.

4. Осуществлен отбор текстурных признаков, обеспечивающих наибольшую достоверность сегментации. Такими признаками стали второй угловой момент (энергия), обратный дифференциальный момент (гомогенность) и энтропия.

5. Разработан алгоритм сегментации АС радиолокационных изображений для определения водной поверхности и суши на основе применения АКМГ к значениям текстурных признаков. Показано, что АС обеспечивает повторяемость результатов сегментации, снижает время вычислений на 35–50 % и в среднем повышает достоверность на 1,84 %.

3. Алгоритмы повышения достоверности сегментации радиолокационных изображений для определения водной поверхности и суши

Глава посвящена разработке алгоритмов, позволяющих повысить достоверность ранее выполненной сегментации на классы водной поверхности и суши. Алгоритмы основаны на комплексировании информации из разных источников.

Разрабатываются алгоритмы:

- комплексирования результатов сегментации многоканального радиолокационного изображения;*
- формирования маски классов поверхности по результатам анализа значений высот из цифровой модели рельефа.*

3.1 Алгоритм комплексирования результатов сегментации многоканального радиолокационного изображения

3.1.1. Постановка задачи. В процессе разработки АС была получена таблица значений границ между классами для разных текстурных признаков (Таблица 16). По ней можно заметить, что пороговые значения для ко-поляризаций и кросс-поляризаций значительно отличаются. Это вызвано особенностями рассеяния сигналов с разными видами поляризации, которые обычно выражаются в следующем:

- 1) поляризация *HH* чувствительна к шероховатости и текстуре поверхности [102];
- 2) поляризация *VV* сильнее всего отражает вертикальные поверхности, такие как растительность и вода;

- 3) поляризация HV показывает изменения в структуре поверхности и часто используется для идентификации территории водно-болотных угодий и типов почв;
- 4) поляризация VH позволяет отличать различные типы растительности и водных тел.

На основании перечисленных особенностей можно сделать вывод о том, что каждый тип поляризации вносит свой вклад в определение свойств исследуемой поверхности и помогает сформировать итоговое представление об объектах местности. Соответственно, путем комплексирования результатов сегментации по разным видам поляризации можно получить более достоверное распределение пикселей по классам. Для этого необходимо определить способ принятия решений о классе пикселей на основе классификаций в разных каналах.

3.1.2. Исследуемые способы. Для решения поставленной задачи будут исследоваться следующие способы принятия решений:

- 1) принцип большинства [103] – пиксель идентифицируется как вода, если как минимум 3 из 4 каналов его идентифицируют как воду;
- 2) принцип большинства с учетом равенства «голосов» – в случае ничьей пиксель классифицируется как вода;
- 3) строгое согласие [104] – пиксель классифицируется как вода, только если все каналы его классифицируют как воду;
- 4) мягкое согласие – пиксель классифицируется как вода, если хотя бы один канал его классифицирует как воду;
- 5) взвешенное голосование – каналам назначаются веса, далее результат v вычисляется по формуле:

$$v = \omega_1 v_1 + \omega_2 v_2 + \omega_3 v_3 + \omega_4 v_4, \quad (21)$$

где v_i – результат классификации i -го канала ($v_i = 1$, если пиксель – вода, и $v_i = 0$, если пиксель – суша),

ω_i – вес i -го канала.

Полученное таким образом значение сравнивается с заданным порогом t и, если $v \geq t$, пиксель классифицируется как вода, иначе – как суша.

3.1.3. Исследование взвешенного голосования. Для принятия решений на основе взвешенного голосования требуется определить два основных параметра – веса каналов ω_i и пороговое значение t , при достижении которого пиксель будет классифицироваться как вода. Были проведены экспериментальные исследования зависимости достоверности сегментации от разных комбинаций значений этих параметров для исследуемых текстурных признаков и экспериментальных изображений. Значения, полученные в результате данных экспериментов, приведены в таблицах 19–21. Полужирным шрифтом выделено наибольшее значение достоверности сегментации (в случае равенства выделено то значение, которое получено при условиях, наиболее близких к оптимальным, определенным далее).

Таблица 19 – Оценка достоверности сегментации при комплексировании на основе взвешенного голосования для текстурного признака энергии

№ изобр.	ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	Acc_B	Acc_C	Acc
1	0,3	0,2	0,3	0,2	0,3	0,9906	0,9476	0,9691
					0,4	0,9786	0,9903	0,9845
					0,5	0,9784	0,9930	0,9857
					0,6	0,9767	0,9940	0,9854
	0,2	0,3	0,2	0,3	0,3	0,9787	0,9889	0,9838
					0,4	0,9786	0,9903	0,9845
					0,5	0,9708	0,9920	0,9814
					0,6	0,9691	0,9930	0,9810
2	0,3	0,2	0,3	0,2	0,3	0,9861	0,8279	0,9070
					0,4	0,9838	0,8537	0,9188
					0,5	0,9791	0,8744	0,9268
					0,6	0,9783	0,8775	0,9279
	0,2	0,3	0,2	0,3	0,3	0,9850	0,8459	0,9154
					0,4	0,9838	0,8537	0,9188
					0,5	0,9808	0,8671	0,9284
					0,6	0,9799	0,8792	0,9295
3	0,3	0,2	0,3	0,2	0,3	0,9857	0,9847	0,9851
					0,4	0,9830	0,9893	0,9861
					0,5	0,9830	0,9893	0,9861

№ изобр.	ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	Acc_B	Acc_C	Acc
	0,2	0,3	0,2	0,3	0,6	0,9830	0,9893	0,9861
					0,3	0,9830	0,9893	0,9861
					0,4	0,9830	0,9893	0,9861
					0,5	0,9497	0,9997	0,9747
					0,6	0,9497	0,9997	0,9747

Таблица 20 – Оценка достоверности сегментации при комплексировании на основе взвешенного голосования для текстурного признака гомогенности

№ изобр.	ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	Acc_B	Acc_C	Acc
1	0,3	0,2	0,3	0,2	0,3	0,9927	0,9300	0,9613
					0,4	0,9833	0,9808	0,9821
					0,5	0,9830	0,9867	0,9849
					0,6	0,9819	0,9882	0,9850
	0,2	0,3	0,2	0,3	0,3	0,9835	0,9779	0,9807
					0,4	0,9833	0,9808	0,9821
					0,5	0,9776	0,9836	0,9806
					0,6	0,9765	0,9850	0,9807
2	0,3	0,2	0,3	0,2	0,3	0,9434	0,9504	0,9469
					0,4	0,9292	0,9670	0,9481
					0,5	0,9255	0,9688	0,9471
					0,6	0,9239	0,9691	0,9465
	0,2	0,3	0,2	0,3	0,3	0,9309	0,9660	0,9485
					0,4	0,9292	0,9670	0,9481
					0,5	0,8869	0,9860	0,9364
					0,6	0,8854	0,9863	0,9358
3	0,3	0,2	0,3	0,2	0,3	0,9688	0,9981	0,9834
					0,4	0,9659	0,9987	0,9823
					0,5	0,9658	0,9990	0,9824
					0,6	0,9654	0,9991	0,9822
	0,2	0,3	0,2	0,3	0,3	0,9661	0,9985	0,9823
					0,4	0,9659	0,9987	0,9823
					0,5	0,9633	0,9990	0,9811
					0,6	0,9628	0,9991	0,9810

Таблица 21 – Оценка достоверности сегментации при комплексировании на основе взвешенного голосования для текстурного признака энтропии

№ изобр.	ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	Acc_B	Acc_C	Acc
1	0,3	0,2	0,3	0,2	0,3	0,9823	0,9547	0,9685
					0,4	0,9711	0,9907	0,9809
					0,5	0,9708	0,9939	0,9823

№ изобр.	ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	Acc_B	Acc_C	Acc
	0,2	0,3	0,2	0,3	0,6	0,9702	0,9943	0,9823
					0,3	0,9713	0,9895	0,9804
					0,4	0,9711	0,9907	0,9809
					0,5	0,9625	0,9926	0,9776
					0,6	0,9619	0,9931	0,9775
2	0,3	0,2	0,3	0,2	0,3	0,9445	0,9037	0,9241
					0,4	0,9398	0,9146	0,9272
					0,5	0,9381	0,9149	0,9265
					0,6	0,8876	0,9770	0,9323
	0,2	0,3	0,2	0,3	0,3	0,9630	0,8565	0,9097
					0,4	0,9398	0,9146	0,9272
					0,5	0,9395	0,9146	0,9270
					0,6	0,8889	0,9767	0,9328
3	0,3	0,2	0,3	0,2	0,3	0,9662	0,9983	0,9823
					0,4	0,9620	0,9989	0,9805
					0,5	0,9618	0,9994	0,9806
					0,6	0,9612	0,9994	0,9803
	0,2	0,3	0,2	0,3	0,3	0,9623	0,9987	0,9805
					0,4	0,9620	0,9989	0,9805
					0,5	0,9611	0,9991	0,9801
					0,6	0,9604	0,9991	0,9797

Полученные результаты показывают, что однозначно лучшей комбинации параметров нет – условия, при которых достигается наибольшая достоверность, разнятся. Вследствие этого необходимо использовать значения весов и порога, при которых средняя достоверность сегментации будет наибольшая.

Результаты расчета средней достоверности сегментации по трем изображениям при разных значениях параметров взвешенного голосования для каждого текстурного признака приведены в таблицах 22–24. Полужирным шрифтом выделено наибольшее среднее значение достоверности.

Таблица 22 – Результаты расчета средней достоверности сегментации при разных значениях параметров взвешенного голосования для признака энергии

ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	№1	№2	№3	Acc
0,3	0,2	0,3	0,2	0,3	0,9691	0,9070	0,9851	0,9537
				0,4	0,9845	0,9188	0,9861	0,9631
				0,5	0,9857	0,9268	0,9861	0,9662
				0,6	0,9854	0,9279	0,9861	0,9665
0,2	0,3	0,2	0,3	0,3	0,9838	0,9154	0,9861	0,9618
				0,4	0,9845	0,9188	0,9861	0,9631
				0,5	0,9814	0,9284	0,9747	0,9615
				0,6	0,9810	0,9295	0,9747	0,9617

Таблица 23 – Результаты расчета средней достоверности сегментации при разных значениях параметров взвешенного голосования для признака гомогенности

ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	№1	№2	№3	Acc
0,3	0,2	0,3	0,2	0,3	0,9613	0,9469	0,9834	0,9639
				0,4	0,9821	0,9481	0,9823	0,9708
				0,5	0,9849	0,9471	0,9824	0,9715
				0,6	0,9850	0,9465	0,9822	0,9712
0,2	0,3	0,2	0,3	0,3	0,9807	0,9485	0,9823	0,9705
				0,4	0,9821	0,9481	0,9823	0,9708
				0,5	0,9806	0,9364	0,9811	0,9660
				0,6	0,9807	0,9358	0,9810	0,9658

Таблица 24 – Результаты расчета средней достоверности сегментации при разных значениях параметров взвешенного голосования для признака энтропии

ω_{VV}	ω_{VH}	ω_{HH}	ω_{HV}	t	№1	№2	№3	Acc
0,3	0,2	0,3	0,2	0,3	0,9685	0,9241	0,9823	0,9583
				0,4	0,9809	0,9272	0,9805	0,9629
				0,5	0,9823	0,9265	0,9806	0,9631
				0,6	0,9823	0,9323	0,9803	0,9650
0,2	0,3	0,2	0,3	0,3	0,9804	0,9097	0,9805	0,9569
				0,4	0,9809	0,9272	0,9805	0,9629
				0,5	0,9776	0,9270	0,9801	0,9616
				0,6	0,9775	0,9328	0,9797	0,9633

На основании полученных данных можно сделать вывод о том, что наибольшая достоверность сегментации достигается при весах $\omega_i = 0,3$ для каналов с ко-поляризацией и $\omega_i = 0,2$ для каналов с кросс-поляризацией. При этом

значение порога $t = 0,6$ для признаков энергии и энтропии и $t = 0,5$ для признака гомогенности. Стоит отметить, что для гомогенности, в случае выбора порога $t = 0,6$, достоверность падает всего лишь на 0,03 %, что может быть обусловлено погрешностью формирования эталонной маски или сюжетом изображения, поэтому дополнительные исследования на новых изображениях в конечном итоге могут позволить определить порог $t = 0,6$ как универсальный для всех признаков. Тем не менее, в рамках данной работы для признака гомогенности будет использоваться порог $t = 0,5$.

3.1.4. Исследование способов принятия решений. Для определения способа принятия решений, позволяющего получить наибольшую достоверность сегментации при комплексировании по разным видам поляризации, были проведены экспериментальные исследования, результаты которых представлены в таблицах 25–27.

Таблица 25 – Оценка достоверности способов принятия решения для текстурного признака энергии

№ изобр.	Способ принятия решений	Acc_B	Acc_C	Acc
1	Большинства	0,9689	0,9957	0,9823
	Большинства (при ничьей – вода)	0,9786	0,9903	0,9845
	Строгое согласие	0,9609	0,9987	0,9798
	Мягкое согласие	0,9907	0,9462	0,9685
	Взвешенное голосование	0,9767	0,9940	0,9854
2	Большинства	0,9752	0,8998	0,9375
	Большинства (при ничьей – вода)	0,9838	0,8537	0,9188
	Строгое согласие	0,9655	0,9182	0,9419
	Мягкое согласие	0,9910	0,7549	0,8730
	Взвешенное голосование	0,9783	0,8775	0,9279
3	Большинства	0,9497	0,9997	0,9747
	Большинства (при ничьей – вода)	0,9830	0,9893	0,9861
	Строгое согласие	0,9463	0,9998	0,9731
	Мягкое согласие	0,9865	0,9847	0,9851
	Взвешенное голосование	0,9830	0,9893	0,9861

Таблица 26 – Оценка достоверности способов принятия решения для текстурного признака гомогенности

№ изобр.	Способ принятия решений	Acc_B	Acc_C	Acc
1	Большинства	0,9762	0,9909	0,9836
	Большинства (при ничьей – вода)	0,9833	0,9808	0,9821
	Строгое согласие	0,9694	0,9968	0,9831
	Мягкое согласие	0,9928	0,9270	0,9599
	Взвешенное голосование	0,9830	0,9867	0,9849
2	Большинства	0,8816	0,9881	0,9349
	Большинства (при ничьей – вода)	0,9292	0,9670	0,9481
	Строгое согласие	0,8608	0,9916	0,9262
	Мягкое согласие	0,9450	0,9495	0,9473
	Взвешенное голосование	0,9255	0,9688	0,9471
3	Большинства	0,9628	0,9994	0,9811
	Большинства (при ничьей – вода)	0,9659	0,9987	0,9823
	Строгое согласие	0,9604	0,9997	0,9801
	Мягкое согласие	0,9690	0,9979	0,9834
	Взвешенное голосование	0,9658	0,9990	0,9824

Таблица 27 – Оценка достоверности способов принятия решения для текстурного признака энтропии

№ изобр.	Способ принятия решений	Acc_B	Acc_C	Acc
1	Большинства	0,9616	0,9963	0,9789
	Большинства (при ничьей – вода)	0,9711	0,9907	0,9809
	Строгое согласие	0,9566	0,9984	0,9775
	Мягкое согласие	0,9825	0,9534	0,9680
	Взвешенное голосование	0,9702	0,9943	0,9823
2	Большинства	0,8873	0,9770	0,9322
	Большинства (при ничьей – вода)	0,9398	0,9146	0,9272
	Строгое согласие	0,8169	0,9957	0,9063
	Мягкое согласие	0,9677	0,8456	0,9066
	Взвешенное голосование	0,8876	0,9770	0,9323
3	Большинства	0,9602	0,9995	0,9799
	Большинства (при ничьей – вода)	0,9620	0,9989	0,9805
	Строгое согласие	0,9580	0,9999	0,9790

№ изобр.	Способ принятия решений	Acc_B	Acc_C	Acc
	Мягкое согласие	0,9665	0,9981	0,9823
	Взвешенное голосование	0,9612	0,9994	0,9803

По полученным результатам однозначно нельзя определить лучший способ принятия решений, вследствие чего необходимо рассчитывать среднюю достоверность сегментации. При этом простой метод большинства ни разу не показал наилучший результат, поэтому его следует исключить из анализа. Результаты оценки средней по всем изображениям достоверности сегментации в зависимости от способа принятия решений представлены в таблицах 28–30.

Таблица 28 – Оценка средней достоверности сегментации по способам принятия решения для текстурного признака энергии

Способ принятия решений	№1	№2	№3	Acc
Большинства (при ничьей – вода)	0,9845	0,9188	0,9861	0,9631
Строгое согласие	0,9798	0,9419	0,9731	0,9649
Мягкое согласие	0,9685	0,8730	0,9851	0,9422
Взвешенное голосование	0,9854	0,9279	0,9861	0,9665

Таблица 29 – Оценка средней достоверности сегментации по способам принятия решения для текстурного признака гомогенности

Способ принятия решений	№1	№2	№3	Acc
Большинства (при ничьей – вода)	0,9821	0,9481	0,9823	0,9708
Строгое согласие	0,9831	0,9262	0,9801	0,9631
Мягкое согласие	0,9599	0,9473	0,9834	0,9636
Взвешенное голосование	0,9849	0,9471	0,9824	0,9714

Таблица 30 – Оценка средней достоверности сегментации по способам принятия решения для текстурного признака энтропии

Способ принятия решений	№1	№2	№3	Acc
Большинства (при ничьей – вода)	0,9809	0,9272	0,9805	0,9629
Строгое согласие	0,9775	0,9063	0,9790	0,9543
Мягкое согласие	0,9680	0,9066	0,9823	0,9523
Взвешенное голосование	0,9823	0,9323	0,9803	0,9650

По результатам оценки средней достоверности сегментации можно сделать вывод, что с целью комплексирования результатов сегментации по разным видам поляризации следует использовать взвешенное голосование для принятия решений о классе пикселей, так как для каждого текстурного признака этот способ дал наибольшую достоверность сегментации.

Примеры сегментации, полученной с помощью комплексирования на основе взвешенного голосования, приведены на рисунках 29–31.




Рисунок 29 – Результат комплексирования сегментаций по разным видам поляризации изображения №1 по признаку энтропии




Рисунок 30 – Результат комплексирования сегментаций по разным видам поляризации изображения №2 по признаку энергии



Рисунок 31 – Результат комплексирования сегментаций по разным видам поляризации изображения №3 по признаку гомогенности

3.1.5. Оценка повышения достоверности сегментации при комплексировании. Для проверки эффективности выбранного способа повышения досто-

верности сегментации необходимо сравнить значения средней по четырем каналам достоверности сегментации $A_{cc_{cp}}$ (таблицы 10–12) и значения достоверности после применения описанного алгоритма комплексирования, представленные в таблицах 28–30. Результаты данного сравнения приведены в таблице 31.

Таблица 31 – Оценка изменения достоверности после комплексирования

№ изобр.	Признак	$A_{cc_{cp}}$	A_{cc}	ΔA_{cc}
1	Энергия	0,9788	0,9854	+0,0066
	Гомогенность	0,9772	0,9849	+0,0077
	Энтропия	0,9763	0,9809	+0,0046
2	Энергия	0,9255	0,9279	+0,0024
	Гомогенность	0,9391	0,9471	+0,0080
	Энтропия	0,9181	0,9323	+0,0142
3	Энергия	0,9798	0,9861	+0,0063
	Гомогенность	0,9817	0,9824	+0,0007
	Энтропия	0,9804	0,9803	-0,0001

Результаты экспериментов показывают, что в подавляющем большинстве случаев достоверность сегментации увеличилась. Единственный отрицательный прирост наблюдался для третьего изображения при использовании признака энтропии. Тем не менее, данный результат нельзя назвать однозначно плохим – во-первых, изменение в достоверности оказалось на уровне погрешности вычислений, во-вторых, если посмотреть на достоверность сегментации по отдельным видам поляризации (0,9824, 0,9797, 0,9798 и 0,9797 для HH , HV , VV и VH соответственно), можно заметить, что в трех каналах из четырех значения хуже, чем после применения алгоритма комплексирования, поэтому при случайном выборе используемой для сегментации поляризации с вероятностью 0,75 полученный результат уступал бы предложенному алгоритму комплексирования по достоверности.

Для адекватной интерпретации результатов работы алгоритма полученное изменение в достоверности следует перевести в другую метрику – площадь земной поверхности по формуле

$$\Delta S = N_{\text{пикс}} S_{\text{пикс}} \Delta Acc, \quad (22)$$

где $N_{\text{пикс}}$ – количество пикселей анализируемого изображения, $S_{\text{пикс}}$ – площадь поверхности, соответствующая одному пикселю, ΔAcc – изменение в достоверности сегментации.

Учитывая размеры изображений (23,1 млн., 23,3 млн. и 19,6 млн. пикселей в изображениях №1, №2 и №3 соответственно) и площадь поверхности, соответствующую одному пикселю (39,5 м² для изображений №1 и №2 и 41,2 м² для изображения №3), полученное повышение достоверности от 0,24 % до 1,42 % эквивалентно корректной сегментации от 2,21 до 13,07 км² поверхности, что является достаточно большой величиной для одного маршрута съемки в режиме Stripmap, таким образом использование предложенного алгоритма целесообразно.

3.1.6. Добавление результатов сегментации на основе поляриметрической классификации в алгоритм комплексирования. Поскольку, как было показано в разделе 2.2, сегментация на основе поляриметрической классификации имеет высокую достоверность, ее результаты также могут быть использованы в качестве дополнительного источника информации при принятии решений о классе пикселей. Для этого при выполнении взвешенного голосования следует добавить еще один вес ω_{Pol} , который будет отражать результаты поляриметрической классификации.

Так как наилучшее соотношение между исходными четырьмя весами было уже определено, целесообразно оценить лишь два набора весов с разными порогом – $\omega_1 = \{0,23, 0,18, 0,23, 0,18, 0,18\}$ и $\omega_2 = \{0,22, 0,17, 0,22, 0,17, 0,22\}$. Результаты проведенных экспериментов представлены в таблицах 32–34.

Таблица 32 – Оценка достоверности сегментации при расширенном взвешенном голосовании для текстурного признака энергии

№ изобр.	ω_i	t	Acc_B	Acc_C	Acc
1		0,23	0,9906	0,9476	0,9691

№ изобр.	ω_i	t	Acc_B	Acc_C	Acc
	ω_1	0,36	0,9788	0,9902	0,9845
		0,41	0,9787	0,9929	0,9858
		0,46	0,9769	0,9940	0,9854
		0,54	0,9702	0,9955	0,9829
		0,59	0,9701	0,9955	0,9828
		0,64	0,9665	0,9981	0,9823
		0,69	0,9635	0,9984	0,9810
	ω_2	0,22	0,9906	0,9476	0,9691
		0,34	0,9788	0,9902	0,9845
		0,39	0,9787	0,9929	0,9858
		0,44	0,9771	0,9939	0,9855
		0,56	0,9702	0,9955	0,9829
		0,61	0,9666	0,9981	0,9823
	2	ω_1	0,23	0,9862	0,8276
0,36			0,9843	0,8516	0,9179
0,41			0,9797	0,8709	0,9253
0,46			0,9786	0,8752	0,9269
0,54			0,9763	0,8930	0,9347
0,59			0,9761	0,8948	0,9354
0,64			0,9698	0,9016	0,9357
0,69			0,9673	0,9118	0,9395
ω_2		0,22	0,9866	0,8225	0,9060
		0,34	0,9843	0,8516	0,9179
		0,39	0,9798	0,8705	0,9251
		0,44	0,9790	0,8735	0,9262
		0,56	0,9763	0,8930	0,9347
		0,61	0,9699	0,9011	0,9355
3	ω_1	0,23	0,9856	0,9847	0,9851
		0,36	0,9844	0,9858	0,9851
		0,41	0,9844	0,9858	0,9851
		0,46	0,9830	0,9893	0,9861
		0,54	0,9749	0,9934	0,9842
		0,59	0,9749	0,9934	0,9842
		0,64	0,9749	0,9934	0,9842
		0,69	0,9497	0,9997	0,9747
	ω_2	0,22	0,9864	0,9446	0,9655
		0,34	0,9844	0,9858	0,9851
		0,39	0,9844	0,9858	0,9851
		0,44	0,9844	0,9858	0,9851
		0,56	0,9749	0,9934	0,9842
		0,61	0,9749	0,9934	0,9842

Таблица 33 – Оценка достоверности сегментации при расширенном взвешенном голосовании для текстурного признака гомогенности

№ изобр.	ω_i	t	Acc_B	Acc_C	Acc
1	ω_1	0,23	0,9927	0,9300	0,9613
		0,36	0,9834	0,9808	0,9821
		0,41	0,9831	0,9867	0,9849
		0,46	0,9820	0,9882	0,9851
		0,54	0,9766	0,9909	0,9837
		0,59	0,9766	0,9909	0,9837
		0,64	0,9724	0,9961	0,9843
		0,69	0,9704	0,9966	0,9835
	ω_2	0,22	0,9927	0,9300	0,9613
		0,34	0,9834	0,9808	0,9821
		0,39	0,9831	0,9867	0,9849
		0,44	0,9821	0,9881	0,9851
		0,56	0,9766	0,9909	0,9837
		0,61	0,9725	0,9961	0,9843
2	ω_1	0,23	0,9440	0,9499	0,9469
		0,36	0,9375	0,9536	0,9455
		0,41	0,9342	0,9547	0,9444
		0,46	0,9261	0,9675	0,9468
		0,54	0,9140	0,9698	0,9419
		0,59	0,9128	0,9711	0,9419
		0,64	0,9095	0,9715	0,9405
		0,69	0,8779	0,9883	0,9331
	ω_2	0,22	0,9557	0,9123	0,9340
		0,34	0,9375	0,9536	0,9455
		0,39	0,9348	0,9541	0,9445
		0,44	0,9337	0,9547	0,9442
		0,56	0,9140	0,9698	0,9419
		0,61	0,9105	0,9712	0,9408
3	ω_1	0,23	0,9690	0,9979	0,9834
		0,36	0,9688	0,9980	0,9834
		0,41	0,9686	0,9982	0,9834
		0,46	0,9659	0,9987	0,9823
		0,54	0,9659	0,9987	0,9823
		0,59	0,9658	0,9991	0,9824
		0,64	0,9653	0,9991	0,9822
		0,69	0,9628	0,9994	0,9811
	ω_2	0,22	0,9774	0,9498	0,9636
		0,34	0,9688	0,9980	0,9834
		0,39	0,9688	0,9980	0,9834
		0,44	0,9686	0,9982	0,9834
		0,56	0,9659	0,9987	0,9823
		0,61	0,9658	0,9991	0,9824

Таблица 34 – Оценка достоверности сегментации при расширенном взвешенном голосовании для текстурного признака энтропии

№ изобр.	ω_i	t	Acc_B	Acc_c	Acc
1	ω_1	0,23	0,9823	0,9547	0,9685
		0,36	0,9720	0,9906	0,9813
		0,41	0,9717	0,9938	0,9827
		0,46	0,9703	0,9943	0,9823
		0,54	0,9653	0,9961	0,9807
		0,59	0,9652	0,9961	0,9807
		0,64	0,9628	0,9979	0,9804
		0,69	0,9585	0,9983	0,9784
	ω_2	0,22	0,9826	0,9546	0,9686
		0,34	0,9720	0,9906	0,9813
		0,39	0,9717	0,9938	0,9827
		0,44	0,9712	0,9942	0,9827
		0,56	0,9653	0,9961	0,9807
		0,61	0,9629	0,9979	0,9804
2	ω_1	0,23	0,9501	0,8951	0,9226
		0,36	0,9466	0,9039	0,9253
		0,41	0,9398	0,9126	0,9262
		0,46	0,9216	0,9348	0,9282
		0,54	0,9214	0,9348	0,9281
		0,59	0,9211	0,9350	0,9280
		0,64	0,8856	0,9771	0,9314
		0,69	0,8814	0,9775	0,9294
	ω_2	0,22	0,9530	0,8897	0,9214
		0,34	0,9466	0,9039	0,9253
		0,39	0,9454	0,9041	0,9247
		0,44	0,9229	0,9327	0,9278
		0,56	0,9214	0,9348	0,9281
		0,61	0,9193	0,9351	0,9272
3	ω_1	0,23	0,9665	0,9981	0,9823
		0,36	0,9657	0,9984	0,9821
		0,41	0,9654	0,9986	0,9820
		0,46	0,9620	0,9989	0,9805
		0,54	0,9620	0,9989	0,9805
		0,59	0,9618	0,9994	0,9806
		0,64	0,9612	0,9994	0,9803
		0,69	0,9602	0,9995	0,9799
	ω_2	0,22	0,9780	0,9496	0,9638
		0,34	0,9657	0,9984	0,9821
		0,39	0,9657	0,9984	0,9821
		0,44	0,9654	0,9986	0,9820
		0,56	0,9620	0,9989	0,9805
		0,61	0,9618	0,9994	0,9806

Как и в предыдущем случае, полученные результаты разнятся, поэтому необходимо рассчитать среднюю достоверность сегментации по трем изображениям. Результаты расчетов приведены в таблицах 35–37.

Таблица 35 – Результаты расчета средней достоверности сегментации при расширенном взвешенном голосовании для текстурного признака энергии

ω_i	t	№1	№2	№3	Acc
ω_1	0,23	0,9691	0,9069	0,9851	0,9537
	0,36	0,9845	0,9179	0,9851	0,9625
	0,41	0,9858	0,9253	0,9851	0,9654
	0,46	0,9854	0,9269	0,9861	0,9661
	0,54	0,9829	0,9347	0,9842	0,9673
	0,59	0,9828	0,9354	0,9842	0,9675
	0,64	0,9823	0,9357	0,9842	0,9674
	0,69	0,9812	0,9395	0,9747	0,9651
ω_2	0,22	0,9691	0,9060	0,9655	0,9469
	0,34	0,9845	0,9179	0,9851	0,9625
	0,39	0,9858	0,9251	0,9851	0,9653
	0,44	0,9855	0,9262	0,9851	0,9656
	0,56	0,9829	0,9347	0,9842	0,9673
	0,61	0,9823	0,9355	0,9842	0,9673

Таблица 36 – Результаты расчета средней достоверности сегментации при расширенном взвешенном голосовании для текстурного признака гомогенности

ω_i	t	№1	№2	№3	Acc
ω_1	0,23	0,9613	0,9469	0,9834	0,9639
	0,36	0,9821	0,9455	0,9834	0,9703
	0,41	0,9849	0,9444	0,9823	0,9705
	0,46	0,9851	0,9468	0,9823	0,9714
	0,54	0,9837	0,9419	0,9823	0,9693
	0,59	0,9837	0,9419	0,9824	0,9693
	0,64	0,9843	0,9405	0,9822	0,9690
	0,69	0,9835	0,9331	0,9811	0,9659
ω_2	0,22	0,9613	0,9340	0,9636	0,9530
	0,34	0,9821	0,9455	0,9834	0,9703
	0,39	0,9849	0,9445	0,9834	0,9709
	0,44	0,9851	0,9442	0,9834	0,9709
	0,56	0,9837	0,9419	0,9823	0,9693
	0,61	0,9843	0,9408	0,9824	0,9692

Таблица 37 – Результаты расчета средней достоверности сегментации при расширенном взвешенном голосовании для текстурного признака энтропии

ω_i	t	№1	№2	№3	Acc
ω_1	0,23	0,9685	0,9226	0,9823	0,9578
	0,36	0,9813	0,9253	0,9821	0,9629
	0,41	0,9827	0,9262	0,9820	0,9636
	0,46	0,9823	0,9282	0,9805	0,9637
	0,54	0,9807	0,9281	0,9805	0,9631
	0,59	0,9807	0,9280	0,9806	0,9631
	0,64	0,9804	0,9314	0,9803	0,9640
	0,69	0,9784	0,9294	0,9799	0,9626
ω_2	0,22	0,9686	0,9214	0,9638	0,9513
	0,34	0,9813	0,9253	0,9821	0,9629
	0,39	0,9827	0,9247	0,9821	0,9632
	0,44	0,9827	0,9278	0,9820	0,9642
	0,56	0,9807	0,9281	0,9805	0,9631
	0,61	0,9804	0,9272	0,9806	0,9627

На основе полученных результатов можно определить комбинацию весов и значения порога для достижения наибольшей средней достоверности. В случае с признаками энергии и гомогенности наилучший результат достигается для набора весов $\omega_1 = \{0,23, 0,18, 0,23, 0,18, 0,18\}$ с порогами 0,59 и 0,46 соответственно. Для энтропии ситуация отличается – лучшим является набор весов $\omega_2 = \{0,22, 0,17, 0,22, 0,17, 0,22\}$ с порогом 0,44.

Примеры результатов сегментации, получаемые с помощью второго варианта алгоритма комплексирования, приведены на рисунках 32–34.



Рисунок 32 – Результат сегментации изображения №1 с помощью второго варианта алгоритма комплексирования на основе признака гомогенности




Рисунок 33 – Результат сегментации изображения №2 с помощью второго варианта алгоритма комплексирования на основе признака энтропии




Рисунок 34 – Результат сегментации изображения №3 с помощью второго варианта алгоритма комплексирования на основе признака энергии

3.1.7. Оценка повышения достоверности. Выполним аналогичное п. 3.1.5 сравнение средней по четырем каналам достоверности сегментации $A_{ср}$ (таблицы 10–12) со значениями, полученными после комплексирования (таблицы 35–37). Результаты приведены в таблице 38.

Таблица 38 – Оценка изменения достоверности после комплексирования с добавлением результатов сегментации на основе поляриметрической классификации

№ изобр.	Признак	$A_{ср}$	$A_{сс}$	$\Delta A_{сс}$
1	Энергия	0,9788	0,9828	+0,0040
	Гомогенность	0,9772	0,9851	+0,0079
	Энтропия	0,9763	0,9827	+0,0064
2	Энергия	0,9255	0,9354	+0,0099
	Гомогенность	0,9391	0,9468	+0,0077
	Энтропия	0,9181	0,9278	+0,0097
3	Энергия	0,9798	0,9842	+0,0044
	Гомогенность	0,9817	0,9823	+0,0006
	Энтропия	0,9804	0,9820	+0,0016

При добавлении результатов сегментации на основе поляриметрической классификации достоверность сегментации увеличилась во всех случаях. При этом, если сравнивать с результатами без них (Таблица 31), можно заметить, что в разных случаях разные варианты алгоритма дают наибольший прирост в достоверности. Во втором варианте алгоритма максимальное изменение достоверности составило +0,99 % (эквивалентно 9,11 км² по формуле 35) и оказалось немного меньше, чем в первом, однако среднее увеличение достоверности больше: +0,58 % против +0,56 %.

Таким образом, оба варианта алгоритма комплексирования результатов сегментации многоканального радиолокационного изображения могут быть использованы для повышения достоверности сегментации.

3.2 Алгоритм формирования маски классов поверхности по результатам анализа относительных значений высот из цифровой модели рельефа

3.2.1. Постановка задачи. В настоящее время доступны цифровые модели рельефа [105], содержащие низкодетальные данные о высотах земной поверхности. В связи с этим, при наличии геодезической привязки на изображении появляется возможность сопоставить радиолокационное изображение и фрагмент ЦМР, покрывающий соответствующий участок Земли. Так как ЦМР содержит информацию о высотах, а некоторые объекты, такие как вода и холмы или горы, имеют характерные топографические признаки, то результаты сегментации можно уточнить с помощью данных ЦМР [45, 106].

Таким образом, алгоритм повышения достоверности сегментации на основе ЦМР подразумевает:

- 1) получение карты высот по данным ЦМР для каждого пикселя исходного изображения;

- 2) формирование маски классов поверхности на основе полученной карты высот;
- 3) уточнение исходных результатов сегментации путем комплексирования с маской классов.

3.2.2. Разработка алгоритма. Первый шаг алгоритма обусловлен тем, что пространственное разрешение ЦМР существенно ниже разрешения, получаемого при РСА-съёмке. В результате возникает несоответствие сеток: значения высот заданы лишь для более грубой регулярной сетки, тогда как для пикселей РСА-изображения требуется более детализированная информация. Поэтому высоты для этих пикселей определяются на основе исходной ЦМР с использованием процедур интерполяции или аппроксимации. В случае применения итерационных методов уточнения результат может зависеть от начального приближения. Вопрос обеспечения высокой точности восстановления высот для всех пикселей изображения в данной работе не рассматривается.

Вторым шагом алгоритма является формирование маски классов поверхности по значениям карты высот. При этом использование абсолютных значений для классификации по принципу «самые низкие значения соответствуют водным объектам» в большинстве случаев приведет к серьезным ошибкам, так как данный подход не учитывает возможные изменения средней высоты рельефа местности на протяжении маршрута съёмки. Например, река, текущая вниз по склону холма, в своей наивысшей точке будет иметь большую высоту, чем поля, расположенные ниже по течению, также горное озеро будет располагаться выше ближайших предгорий. Вследствие этого классификацию необходимо выполнять с помощью оконной обработки, основанной на анализе относительных значений высот определенного участка местности.

Третий шаг алгоритма подразумевает принятие решений о классах пикселей с учетом полученной маски. Возможны различные варианты как для одной

исходной сегментации, так и для нескольких, однако в данной работе будет рассмотрен только случай с одной сегментацией.

3.2.3. Разработка алгоритма формирования маски классов поверхности. Как было сказано ранее, основой алгоритма является анализ относительных значений высот участка местности. Для этого используются базовые знания о характерном для определенных типов поверхности рельефе. Так, водные объекты естественного происхождения (озера, реки, моря и т.д.) располагаются в низинах, также они не подвержены резким перепадам высот, поэтому, анализируя рельеф обрабатываемого участка местности, можно сделать вывод, присутствует ли на нем водный объект. Подобную классификацию удобно выполнять путем сравнения средних значений высот целевого фрагмента изображения (для которого принимается решение о его принадлежности классу воды целиком) и его некоторой окрестности (которая дает представление об относительном положении анализируемого участка рельефа) – в дальнейшем, малого (размером $S \times S$) и большого (размером $L \times L$) окна обработки соответственно. Если средняя высота в малом окне меньше, чем в большом, ($H_s < H_l$) и при этом малое окно однородно (т.е. местность имеет постоянную высоту), то можно классифицировать данный фрагмент как водную поверхность.

Из-за того, что ЦМР содержит низкодетальные данные, плавные изменения в высоте, присущие водным объектам, в большинстве случаев представляются скачкообразно, с четкой линейной границей, что продемонстрировано на рисунке 35. В случае если малое окно попадает на такую границу, условие однородности не будет выполняться, в результате чего произойдет ошибка классификации, вызванная особенностями формирования ЦМР. Для устранения данной ошибки вводится дополнительная проверка, позволяющая идентифицировать подобные случаи и выполнить корректную классификацию анализируемой области.




Рисунок 35 – Пример скачкообразного изменения высоты реки на ЦМР

Суть данной проверки заключается в определении линейности границы между двумя уровнями высот. Для этого сначала извлекаются координаты всех граничных точек $\{(x_i, y_i)\}$, после чего вычисляется центр масс данной границы:

$$m_x = \frac{\sum x_i}{N}, m_y = \frac{\sum y_i}{N}, \quad (23)$$

где m_x, m_y – координаты центра масс, N – число граничных точек.

Дальнейшие вычисления производятся относительно координат центра масс, что позволяет устранить влияние положения границы внутри обрабатываемого окна. Рассчитываются вторые центральные моменты инерции относительно осей X и Y S_{xx} и S_{yy} и центробежный момент S_{xy} :

$$S_{xx} = \frac{\sum (x_i - m_x)^2}{N}, S_{yy} = \frac{\sum (y_i - m_y)^2}{N}, S_{xy} = \frac{\sum (x_i - m_x)(y_i - m_y)}{N}. \quad (24)$$

Далее с помощью метода главных компонент вычисляется угол ориентации главной оси инерции $\theta = 0,5 \cdot \arctg\left(\frac{2S_{xy}}{S_{xx} - S_{yy}}\right)$ и производится поворот системы координат на угол θ , в результате чего ось X начинает совпадать с главной осью инерции. Последним шагом является вычисление ошибки $E_1 = \frac{\sum y_i'^2}{N}$, где y_i' – ордината координат граничных точек в новой системе координат.

Интерпретация значения ошибки E_1 позволяет принять решение о линейности границы. В случае идеально прямой линии $E_1 = 0$, однако с учетом погрешностей в вычислениях и в данных ЦМР такое значение практически недостижимо, в результате чего приходится вводить некоторый допуск на отклонение от линейной формы. В ходе ряда проведенных экспериментов было принято решение идентифицировать границу как линейную при $E_1 < 0,25$, что ставит достаточно жесткое требование к линейности формы границы.

Выбор размера окна обработки влияет на способность классифицировать относительно небольшие водные объекты. Чем больше окно, тем менее чувствителен алгоритм к локальным изменениям в рельефе местности. При этом в случае наличия на изображении крупных водных объектов (некоторые озера, моря, океаны), условие $H_s < H_l$ не позволит их корректно классифицировать, поскольку уже на расстоянии в 1–2 малых окна от берега средняя высота в обоих окнах станет одинаковой. Следовательно, условие классификации необходимо преобразовать к виду $H_s \leq H_l$.

Несмотря на то, что подобная классификация показывает достаточно высокую достоверность определения водных объектов на экспериментальных изображениях, о чем будет сказано в дальнейшем, можно сделать только *предварительный* вывод о принадлежности обнаруженных объектов к классу водной поверхности. Это связано с тем, что существуют и неводные объекты, которые имеют аналогичный характер относительных высот, удовлетворяющий критерию классификации. Примерами таких объектов могут служить большое поле либо ровная долина между гор.

Тем не менее, знание о форме рельефа водных объектов позволяет выполнить другую классификацию, результаты которой в случае достоверности данных ЦМР также будут являться достоверными. Анализируя значения средних высот и проверяя однородность, можно определить, какие участки рельефа од-

однозначно *не являются* водными объектами. Например, если средняя высота малого окна превышает среднюю высоту большого окна на некоторую величину δ , т.е. если $H_s > H_l + \delta$, то анализируемый фрагмент не является водным. Аналогично, если малое окно имеет сильную неоднородность (количество уникальных значений высоты K больше пороговой величины k), оно также однозначно не относится к водному классу. Кроме того, целесообразно оценивать величину наклона поверхности Sl , поскольку ее большие значения обычно характерны для склонов холмов и гор.

Учитывая вышесказанное, по данным ЦМР можно сформировать маску классов трех типов поверхности:

- 1) «вода», к которому относятся пиксели изображения, во время анализа которых было выполнено условие $H_s \leq H_l$ и условие однородности;
- 2) «не вода», к которому относятся пиксели изображения, во время анализа которых было выполнено условие $H_s > H_l + \delta$, условие сильной неоднородности $K > k$ или условие большого перепада высот $Sl > \alpha$, где α – пороговое значение;
- 3) «не определено», к которому относятся пиксели изображения, не удовлетворяющие критериям двух предыдущих классов.

Блок-схема алгоритма формирования маски классов поверхности по данным ЦМР приведена на рисунке 36.

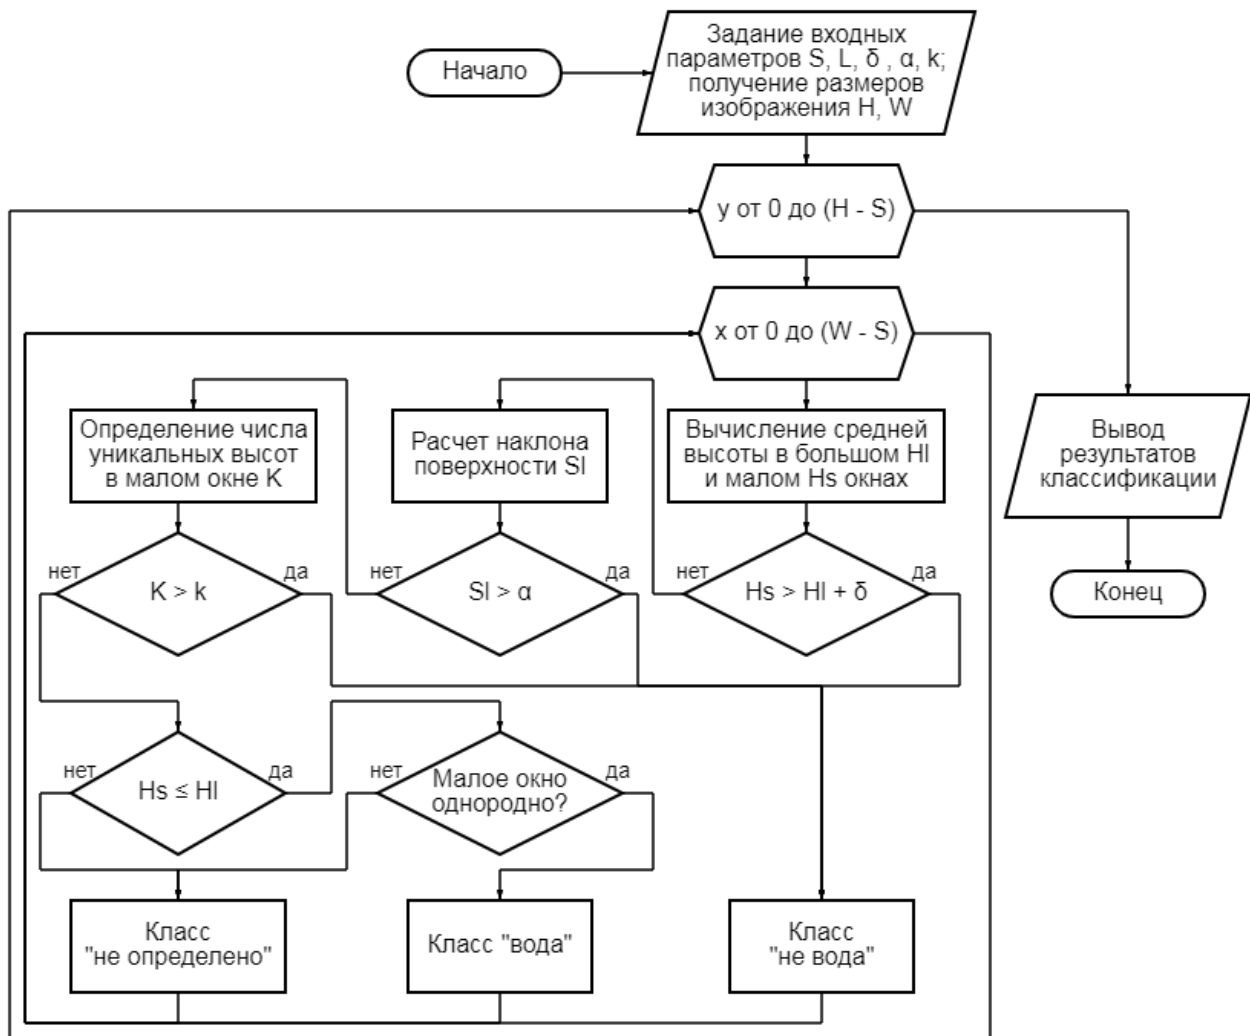


Рисунок 36 – Блок-схема алгоритма создания маски классов по данным ЦМР

Учитывая особенности сформированных классов, на третьем шаге алгоритма целесообразно осуществлять комплексирование имеющихся результатов сегментации с маской классов следующим образом: пиксели класса «не вода» сохраняются на выходном изображении без изменений, пиксели класса «вода» добавляются как дополнительные данные для принятия решений об итоговом классе, а пиксели класса «не определено» не учитываются и, соответственно, не изменяют имеющиеся результаты сегментации.

3.2.4. Задание параметров работы алгоритма. Для создания маски классов по ЦМР необходимо задать некоторые значения параметров, по которым будем приниматься решение о принадлежности тому или иному классу.

Основополагающим параметром является размер малого окна обработки, который отвечает за чувствительность алгоритма к изменениям рельефа. Для его задания необходимо определить физические размеры минимально обнаруживаемого водного объекта (в квадратных метрах), а затем пересчитать их в пиксели изображения. Выбор размера малого окна по минимальной площади поверхности обнаруживаемого водного объекта «привязывает» алгоритм к конкретному маршруту съемки, не допуская абстрактности обработки. Уменьшение размеров малого окна наряду с повышением чувствительности алгоритма к небольшим водным объектам также повышает количество ложных определений суши в качестве воды. Для относительно небольших малых окон (до $200 \times 200 \text{ м}^2$) размер большого окна обработки целесообразно устанавливать в два раза больше размеров малого окна, что позволяет адекватно оценить окрестность.

Формирование класса «не вода» требует задания значений трех параметров: порога превышения средней высоты малого окна над средней высотой большого окна δ , тангенса предельно допустимого угла наклона поверхности $\alpha = \Delta h/d$ (Δh – изменение высоты на противоположных границах малого окна, d – ширина/высота малого окна в метрах) и количества различных значений высоты k в пределах малого окна, которое характеризует данное окно как «сильно неоднородное». Аналогично с размерами окон, ужесточение данных пороговых значений позволяет снизить число ложных классификаций суши в качестве воды, при этом уменьшая размер класса «не вода» и увеличивая размер класса «не определено». При задании этих параметров следует исходить из конкретных потребностей в том, насколько полной должна быть сформированная маска, и тем самым определять, насколько большой вклад ЦМР должна вносить в результат целевой классификации. Для работы алгоритма в дальнейших экспериментах

были выбраны следующие значения: $\delta = 1$ м, $\alpha = 0,05$, $k = 0,2 \cdot w \cdot h$ (w – ширина малого окна, h – высота малого окна в пикселях). Предложенные значения позволяют сохранить адекватный баланс между наполненностью классов «вода» и «не вода» и достоверностью получаемых результатов.

Поскольку основное влияние на формирование классов оказывает размер малого окна, следует провести исследование. Для этого при разных размерах малого окна будем рассчитывать достоверность формирования классов «вода» Acc_w и «не вода» Acc_n (по формулам 28 и 29) и суммарную достоверность Acc (по формуле 27), долю ложных классификаций пикселей класса «вода» в класс «не вода» $F_w = \tilde{P}_w/N_B$ и наоборот $F_n = \tilde{P}_n/N_C$, где \tilde{P}_w – число пикселей класса «вода», классифицированных как «не вода», \tilde{P}_n – число пикселей класса «не вода», классифицированных как «вода», а также суммарную долю ошибок $F = F_w + F_n$. Результаты экспериментов приведены в таблице 39.

Таблица 39 – Оценка зависимости достоверности формирования классов «вода» и «не вода» от размеров малого окна обработки

№ избр.	$SxS, м$	Acc_w	Acc_n	Acc	F_w	F_n	F
1	50x50	0,9725	0,4717	0,7221	0,0110	0,0552	0,0662
	60x60	0,9714	0,5050	0,7382	0,0129	0,0273	0,0402
	70x70	0,9707	0,5343	0,7525	0,0143	0,0182	0,0325
	80x80	0,9703	0,5401	0,7552	0,0152	0,0155	0,0307
	90x90	0,9697	0,5534	0,7615	0,0161	0,0139	0,0300
	100x100	0,9686	0,5677	0,7681	0,0173	0,0128	0,0301
	110x110	0,9678	0,5726	0,7702	0,0180	0,0123	0,0303
	120x120	0,9669	0,5816	0,7742	0,0188	0,0119	0,0307
	130x130	0,9659	0,5850	0,7755	0,0197	0,0116	0,0313
	140x140	0,9643	0,5900	0,7771	0,0204	0,0111	0,0315
	150x150	0,9632	0,5950	0,7791	0,0207	0,0107	0,0314
2	50x50	0,8890	0,6738	0,7814	0,0604	0,0273	0,0877
	60x60	0,8847	0,6922	0,7884	0,0643	0,0137	0,0780
	70x70	0,8818	0,7070	0,7944	0,0668	0,0097	0,0765
	80x80	0,8795	0,7134	0,7965	0,0687	0,0084	0,0771
	90x90	0,8768	0,7156	0,7962	0,0708	0,0077	0,0785
	100x100	0,8722	0,7252	0,7987	0,0745	0,0073	0,0818
	110x110	0,8690	0,7361	0,8025	0,0770	0,0071	0,0841
	120x120	0,8658	0,7335	0,7997	0,0788	0,0069	0,0857

№ изобр.	$S \times S, м$	Acc_w	Acc_n	Acc	F_w	F_n	F
	130x130	0,8625	0,7443	0,8034	0,0825	0,0068	0,0893
	140x140	0,8576	0,7491	0,8033	0,0864	0,0066	0,0930
	150x150	0,8540	0,7447	0,7994	0,0868	0,0064	0,0932
3	50x50	0,9846	0,4856	0,7351	0,0059	0,0240	0,0299
	60x60	0,9844	0,5569	0,7706	0,0056	0,0069	0,0125
	70x70	0,9843	0,6496	0,8169	0,0062	0,0027	0,0089
	80x80	0,9842	0,6604	0,8223	0,0057	0,0016	0,0073
	90x90	0,9840	0,7001	0,8420	0,0060	0,0006	0,0066
	100x100	0,9838	0,7620	0,8729	0,0064	0,0005	0,0069
	110x110	0,9837	0,7356	0,8596	0,0062	0,0004	0,0066
	120x120	0,9836	0,7869	0,8852	0,0068	0,0003	0,0071
	130x130	0,9834	0,8008	0,8921	0,0070	0,0003	0,0073
	140x140	0,9831	0,7763	0,8797	0,0067	0,0002	0,0069
	150x150	0,9828	0,8163	0,8995	0,0071	0,0002	0,0073

Проведенные эксперименты позволяют сделать следующие выводы. Во-первых, для всех изображений на исследуемом диапазоне значений размеров малого окна характерен преимущественный рост количества корректно классифицированных пикселей с увеличением размеров окна, что выражается в повышении достоверности сегментации Acc . Во-вторых, с увеличением размеров окна достоверность формирования класса «вода» снижается медленнее, чем растет достоверность формирования класса «не вода», следовательно, можно частично «пожертвовать» классом «вода» с целью достижения большей суммарной достоверности двух классов. Однако данный подход имеет значительный недостаток: анализируя долю ложных классификаций класса «вода» в класс «не вода» F_w , можно заметить, что она также растет с увеличением размеров окна, а поскольку использование маски классов подразумевает полное сохранение класса «не вода» на итоговом изображении, все подобные ошибки классификации будут также сохранены, и чем больше будут размеры окна, тем больше будет ошибок при формировании результатов сегментации. Таким образом, необходимо найти компромисс между суммарной достоверностью формирования двух классов и числом создаваемых при этом критических ошибок. Для этого сравним среднюю по трем изображениям достоверность \overline{Acc} , долю ошибок классификации $\overline{F_w}$ и

суммарную долю ошибок \bar{F} в пределах размеров от 70x70 до 100x100, так как в этих случаях данные параметры имеют достаточно хорошие значения. Результаты сравнения приведены в таблице 40.

Таблица 40 – Оценка средних значений результатов формирования маски классов

$S \times S, м^2$	\bar{Acc}	\bar{F}_w	\bar{F}
70x70	0,7879	0,0291	0,0393
80x80	0,7913	0,0299	0,0383
90x90	0,7999	0,0310	0,0384
100x100	0,8132	0,0327	0,0396

Исходя из рассчитанных значений, целесообразно использовать малое окно размером 100x100 м², поскольку в этом случае достигается баланс между достоверностью формирования классов «вода» и «не вода», а также количеством вносимых ошибок. Результаты формирования маски классов с указанными значениями параметров приведены на рисунках 37–39. На них белым цветом обозначен класс «вода», черным – класс «не вода» и серым – класс «не определено».



Рисунок 37 – Сформированная маска классов изображения №1



Рисунок 38 – Сформированная маска классов изображения №2



Рисунок 39 – Сформированная маска классов изображения №3

3.2.5. Комплексование результатов сегментации с маской классов.

Способ комплексования маски классов с результатами сегментации был описан ранее: класс «не вода» сохраняется в неизменном виде, класс «не определено» не учитывается, а класс «вода» используется в качестве дополнительного

источника для принятия решения об итоговом классе пикселя. Поскольку на полученных масках число ложных классификаций пикселей суши в класс «вода» минимально, для принятия решения можно использовать правило мягкого согласия: если хотя бы один источник данных (исходный результат сегментации или маска классов) классифицируют пиксель как водную поверхность, то на итоговом изображении он принадлежит водной поверхности; в остальных случаях пиксель классифицируется как суша. Результаты оценки изменения достоверности сегментации при использовании маски классов по ЦМР для различных изображений с исходными данными приведены в таблице 41. В ней в столбце «Исх. сегмент.» указано, какая сегментация использовалась для комплексирования с маской классов (ТА – сегментация на основе текстурного анализа (1 – энергия, 2 – гомогенность, 3 – энтропия), Пол. – сегментация на основе поляриметрической классификации).

Таблица 41 – Оценка изменения достоверности при комплексировании с маской классов

№ изобр.	Исх. сегмент.	Acc_B	Acc_C	Acc	$Acc_{\text{ЦМР}}$	$Acc_{\text{с ЦМР}}$	$Acc_{\text{ЦМР}}$	ΔAcc	
1	ТА1	VV	0,9898	0,9503	0,9700	0,9799	0,9582	0,9690	-0,0010
		VH	0,9687	0,9918	0,9802	0,9754	0,9828	0,9791	-0,0011
		HH	0,9724	0,9968	0,9846	0,9765	0,9860	0,9813	-0,0033
		HV	0,9684	0,9920	0,9802	0,9753	0,9830	0,9792	-0,0010
	ТА2	VV	0,9919	0,9359	0,9639	0,9805	0,9513	0,9659	+0,0020
		VH	0,9768	0,9821	0,9794	0,9769	0,9770	0,9769	-0,0025
		HH	0,9776	0,9935	0,9855	0,9775	0,9841	0,9808	-0,0047
		HV	0,9755	0,9841	0,9798	0,9767	0,9782	0,9775	-0,0023
	ТА3	VV	0,9813	0,9579	0,9696	0,9783	0,9602	0,9692	-0,0004
		VH	0,9614	0,9923	0,9768	0,9743	0,9830	0,9786	+0,0018
		HH	0,9676	0,9962	0,9819	0,9756	0,9849	0,9802	-0,0017
		HV	0,9615	0,9924	0,9770	0,9743	0,9831	0,9787	+0,0017
	Пол.		0,9554	0,9988	0,9771	0,9741	0,9866	0,9803	+0,0032
2	ТА1	VV	0,9797	0,8655	0,9226	0,9217	0,9579	0,9398	+0,0172
		VH	0,9791	0,8812	0,9301	0,9219	0,9563	0,9391	+0,0090
		HH	0,9728	0,8698	0,9213	0,9199	0,9630	0,9415	+0,0202
		HV	0,9803	0,8753	0,9278	0,9221	0,9547	0,9384	+0,0106
	ТА2	VV	0,9269	0,9669	0,9469	0,9118	0,9871	0,9495	+0,0026
		VH	0,8777	0,9872	0,9324	0,9053	0,9888	0,9470	+0,0146

№ изобр.	Исх. сег- мент.	Acc_B	Acc_C	Acc	$Acc_{B\text{ ЦМР}}$	$Acc_{C\text{ ЦМР}}$	$Acc_{\text{ЦМР}}$	ΔAcc	
		<i>HH</i>	0,9303	0,9557	0,9430	0,9114	0,9881	0,9497	+0,0067
		<i>HV</i>	0,8818	0,9865	0,9342	0,9056	0,9887	0,9472	+0,0130
	ТА3	<i>VV</i>	0,8816	0,9781	0,9298	0,9031	0,9887	0,9459	+0,0161
		<i>VH</i>	0,9627	0,8565	0,9096	0,9195	0,9463	0,9329	+0,0233
		<i>HH</i>	0,9426	0,9041	0,9233	0,9138	0,9719	0,9429	+0,0196
		<i>HV</i>	0,8247	0,9943	0,9095	0,8967	0,9911	0,9439	+0,0344
	Пол.	0,9217	0,9192	0,9205	0,9107	0,9724	0,9416	+0,0211	
3	ТА1	<i>VV</i>	0,9831	0,9865	0,9848	0,9904	0,9950	0,9927	+0,0079
		<i>VH</i>	0,9481	0,9998	0,9739	0,9842	0,9995	0,9919	+0,0180
		<i>HH</i>	0,9854	0,9874	0,9864	0,9906	0,9953	0,9929	+0,0065
		<i>HV</i>	0,9479	0,9998	0,9738	0,9842	0,9995	0,9919	+0,0181
	ТА2	<i>VV</i>	0,9682	0,9985	0,9833	0,9845	0,9992	0,9919	+0,0086
		<i>VH</i>	0,9624	0,9989	0,9807	0,9843	0,9992	0,9918	+0,0111
		<i>HH</i>	0,9655	0,9994	0,9824	0,9843	0,9995	0,9919	+0,0095
		<i>HV</i>	0,9620	0,9990	0,9805	0,9843	0,9992	0,9918	+0,0113
	ТА3	<i>VV</i>	0,9660	0,9988	0,9824	0,9852	0,9992	0,9922	+0,0098
		<i>VH</i>	0,9606	0,9989	0,9798	0,9843	0,9993	0,9918	+0,0120
		<i>HH</i>	0,9596	0,9997	0,9797	0,9843	0,9995	0,9919	+0,0122
		<i>HV</i>	0,9605	0,9990	0,9797	0,9843	0,9993	0,9918	+0,0121
	Пол.	0,9772	0,9499	0,9636	0,9853	0,9796	0,9824	+0,0188	

Полученные результаты свидетельствуют о том, что данный алгоритм целесообразно применять при сегментации изображений, содержащих участки поверхности, которые имеют схожие с водой свойства отражения сигналов, однако по значениям высот их можно отличить от воды. Среди экспериментальных изображений первое практически не содержит подобных зон, поэтому при комплексировании происходит пересегментация границ водных участков по маске классов, из-за чего достоверность изменяется на небольшую величину то в большую, то в меньшую сторону, независимо от вида исходной сегментации. На изображениях 2 и 3, которые содержат большие зоны горной местности, комплексирование с маской позволяет сильно снизить ошибочную сегментацию суши как воды, в результате для всех исходных сегментаций наблюдается стабильный и значимый прирост в достоверности. Например, для изображения №2

максимальное увеличение в достоверности сегментации на 0,0344 эквивалентно корректной сегментации 31,66 км² поверхности, а для изображения №3 максимальный прирост на 0,0181 соответствует корректной сегментации 14,62 км² поверхности. Также стоит отметить, что чем более достоверна первоначальная сегментация, тем меньшее повышение достоверности достижимо с помощью алгоритма.

Примеры уточнения результатов сегментации по маске классов для изображений №2 и №3 приведены на рисунках 40 и 42.




Рисунок 40 – Пример уточнения результатов сегментации изображения №2 (поляризация *VV*) на основе текстурного признака энергии




Рисунок 41 – Пример уточнения результатов сегментации изображения №3 (поляризация *HV*) на основе текстурного признака гомогенности

При визуальном сравнении изменений в результатах сегментации можно увидеть, что ошибочная сегментация горных склонов в класс водной поверхности стала заметно меньше, однако обнаруженные русла рек стали немного уже, чем были изначально. Также некоторые ложно определенные по маскам классов зоны водной поверхности перенеслись на итоговые изображения.

3.2.6. Альтернативная стратегия формирования маски классов.

Наряду с ранее изложенным принципом применения маски классов поверхности в качестве уточняющего инструмента, целью которого является дополнение имеющихся результатов сегментации, может быть использован и другой подход, при котором сформированная маска является самодостаточным инструментом сегментации. Для этого должны формироваться только два класса из трех – «вода» и «не вода». Самый простой способ сформировать такую маску – отнести все пиксели класса «не определено» в класс «не вода». Полученная указанным способом маска будет по сути являться результатом сегментации, где класс «не вода» будет соответствовать суше.

Сформированные указанным способом маски приведены на рисунках 42–44. Достоверность сегментации составила 0,9779, 0,9325 и 0,9917 для изображений №1, №2 и №3 соответственно, что превышает некоторые исходные результаты сегментаций из таблицы 41.



Рисунок 42 – Сегментация изображения №1 исключительно по маске классов




Рисунок 43 – Сегментация изображения №2 исключительно по маске классов



Рисунок 44 – Сегментация изображения №3 исключительно по маске классов

Несмотря на полученные высокие значения достоверности сегментации исходных изображений, возможны сюжеты, при которых данная вариация алгоритма не отработает настолько хорошо. Например, при наличии большого числа небольших водных объектов, которые по размеру приблизительно соответствуют малому окну обработки, в стандартном варианте алгоритма возможно их частичное отнесение к классу «не определено» из-за неровных границ берегов или малых размеров и корректная сегментация по исходным данным в дальнейшем. Альтернативный вариант алгоритма все эти водные объекты с высокой вероятностью классифицирует как «не вода», что скажется не лучшим образом на достоверности сегментации.

Таким образом, предложенный альтернативный способ формирования маски классов может использоваться для сегментации изображений с высокой достоверностью.

Основные результаты

1. Предложен алгоритм комплексирования результатов сегментации многоканального изображения при помощи взвешенного голосования. В качестве источников данных могут использоваться результаты сегментации изображений, соответствующих разным поляризациям сигнала при съемке, по АС, а также результаты сегментации на основе поляриметрической классификации. Повышение достоверности зависит от используемого текстурного признака, сцены анализируемого изображения и типов источников данных при комплексировании. Максимальное увеличение достоверности составило 1,42 %, что эквивалентно 13,07 км² корректно сегментированной поверхности Земли.

2. Предложен алгоритм формирования маски классов поверхности по данным ЦМР, разделяющий пиксели изображения на классы «вода», «не вода», «не определено» на основе анализа относительных значений высот. Рассмотрены две стратегии применения данного алгоритма. В первой имеющиеся результаты сегментации уточняются с помощью маски классов. Данный способ показал высокую результативность на изображениях, содержащих теневые склоны рельефа, ошибочно классифицированные как вода используемым алгоритмом сегментации: максимальный прирост в достоверности сегментации составил 3,44 % (эквивалентно 31,66 км² поверхности). Вторая стратегия подразумевает выполнение сегментации исключительно на основе маски классов, в которой классы «не вода» и «не определено» объединены в один. Сегментация таким способом позволила корректно классифицировать 93–99 % пикселей изображений.

4. Экспериментальные исследования разработанных алгоритмов сегментации радиолокационных изображений

Предложенные в главах 2 и 3 алгоритмы исследовались на трех натуральных радиолокационных изображениях. В главе 4 проводится исследование разработанных алгоритмов сегментации и повышения достоверности сегментации на статистически представительной выборке данных. Рассматриваются особенности практической реализации предложенных алгоритмов.

4.1 Экспериментальное исследование алгоритма сегментации на основе детерминированного алгоритма кластеризации (Положение 1)

4.1.1. Исходные данные. Для исследования разработанных алгоритмов в главе 4 использовались 80 натуральных радиолокационных изображений (из них 15 полнополяризационных и 8 содержащих по два вида поляризации) от космических аппаратов «RadarSat-2» и «Sentinel-1», которые представляют собой как полные маршруты съемки, так и их фрагменты, содержащие различные сцены. Для исходных маршрутов съемки аналогичным п. 2.2.1 образом были сформированы эталонные маски сегментации. Примеры изображений приведены на рисунке 45.




Рисунок 45 – Примеры натуральных радиолокационных изображений

4.1.2. Результаты экспериментов. Экспериментальные исследования алгоритма AC проводились на всех изображениях из имеющейся выборки. Оценка достоверности выполнялась для каждого из трех отобранных текстурных признаков.

Средние значения достоверности сегментации при использовании АКМГ и K-Means++ для определения центров кластеров, а также результаты замера времени выполнения алгоритмов для текстурных признаков энергии и гомогенности (для энтропии подобные замеры нецелесообразны) приведены в таблице 42.

Таблица 42 – Результаты экспериментов по оценке Положения 1.

Признак	\overline{Acc}_{AKMG}	\overline{Acc}_{KM}	\bar{t}_{TA}, c	\bar{t}_{AKMG}, mc	\bar{t}_{KM}, c
Энергия	0,9348	0,9320	31,56	432	36,51
Гомогенность	0,9559	0,9488	36,89	465	44,32
Энтропия	0,9445	0,9331	–	–	–

Во всех экспериментах достоверность сегментации превысила 90 %, что является удовлетворительным результатом работы АС. Средняя достоверность при кластеризации по АКМГ оказалась слегка выше, чем при использовании K-Means++, что подтверждает данные, полученные в разделе 2.5. При этом обеспечивается повторяемость результатов сегментации, что устраняет главный недостаток алгоритмов на основе кластеризации по методу k -средних. Таким образом, все требования, поставленные к АКМГ, выполнены. Дополнительное преимущество разработанного алгоритма в виде повышения быстродействия в среднем примерно на 45 % также подтверждено. Примеры сегментации изображений с помощью АС приведены на рисунке 46.




Рисунок 46 – Примеры сегментации изображений по алгоритму AC

4.2 Экспериментальное исследование разработанного алгоритма комплексирования результатов сегментации многоканального изображения с помощью взвешенного голосования (Положение 2)

Для оценки обоих вариантов алгоритма комплексирования использовалось 15 полнополяризационных радиолокационных изображений из той же выборки данных, что и при оценке алгоритма AC. Эксперименты проводились для каждого отобранного текстурного признака.

4.2.1. Оценка повышения достоверности при комплексировании результатов сегментации по разным видам поляризации. Результаты оценки изменения достоверности относительно средней по четырем поляризациям, усредненные по выборке данных, приведены в таблице 43.

Таблица 43 – Оценка первого варианта алгоритма комплексирования

Признак	$\overline{Acc}_{ср}$	\overline{Acc}	$\overline{\Delta Acc}$
Энергия	0,9348	0,9445	+0,0097
Гомогенность	0,9559	0,9650	+0,0091
Энтропия	0,9445	0,9519	+0,0074

Для каждого текстурного признака наблюдается среднее повышение достоверности на 0,7–1,0 % относительно АС. Максимально полученный прирост составил 1,36 %, 1,86 % и 2,42 % соответственно. Примеры работы первого вариант алгоритма комплексирования приведены на рисунке 47.




Рисунок 47 – Примеры работы первого варианта алгоритма комплексирования

4.2.2 Оценка повышения достоверности при комплексировании результатов сегментации по разным видам поляризации и результатов сегментации на основе поляриметрической классификации. Результаты оценки изменения достоверности при добавлении сегментации на основе поляриметрической классификации относительно средней достоверности по четырем поляризациям, усредненные по выборке данных, приведены в таблице 44.

Таблица 44 – Оценка второго варианта алгоритма комплексирования

Признак	$\overline{Acc}_{ср}$	\overline{Acc}	$\Delta\overline{Acc}$
Энергия	0,9348	0,9474	+0,0126
Гомогенность	0,9559	0,9291	+0,0085
Энтропия	0,9445	0,9925	+0,0115

Для текстурных признаков энергии и энтропии добавление результатов сегментации на основе поляриметрической классификации в качестве источника данных позволило достичь на 0,3–0,4 % большего повышения достоверности в среднем. В случае с признаком гомогенности ситуация обратная – наблюдается понижение на 0,06 % относительно первого варианта. Максимальный прирост в достоверности для энергии, гомогенности и энтропии составил 1,53 %, 1,29 % и 2,47 % соответственно. Примеры работы второго варианта алгоритма комплексирования приведены на рисунке 48.




Рисунок 48 – Примеры работы второго варианта алгоритма комплексирования

Таким образом, оба варианта алгоритма комплексирования показывают стабильное повышение достоверности сегментации относительно среднего по четырем каналам значения, что подтверждает целесообразность их применения в задаче повышения достоверности сегментации радиолокационных изображений.

4.3. Экспериментальное исследование алгоритма формирования маски классов поверхности по данным ЦМР (Положение 3)

4.3.1. Исследование применения маски классов поверхности для уточнения результатов сегментации. Исследование первого варианта алгоритма формирования маски классов поверхности для повышения достоверности сегментации проводилось на 12 радиолокационных изображениях, содержащих теневые склоны рельефа.

Во всех проведенных экспериментах наблюдалось повышение достоверности сегментации за счет сильного уменьшения некорректной классификации теневых склонов как водной поверхности. Средний прирост составил 2,98 %, максимальный – 4,67 %. Пример использования маски классов поверхности для повышения достоверности сегментации приведен на рисунке 49.



Рисунок 49 – Пример применения маски классов поверхности для уточнения результатов сегментации (слева – результат сегментации с помощью АС изображения с поляризацией *HH* по признаку гомогенности, по центру – сформированная маска классов поверхности, справа – результат комплексирования)

4.3.2. Исследование применения маски классов поверхности для получения независимых результатов сегментации. Исследование второго варианта алгоритма формирования маски классов проводилось на 27 радиолокационных изображениях, содержащих уникальные сцены местности.

Полученные значения достоверности составили от 93,65 % до 99,15 %. Примеры сегментации по маске классов приведены на рисунке 50.




Рисунок 50 – Примеры сегментации полностью на основе маски классов поверхности

Таким образом, оба варианта использования маски классов поверхности по данным ЦМР подтверждают свою эффективность в плане повышения и достижения высокой достоверности сегментации соответственно.

4.4 Реализация специального программного обеспечения сегментации радиолокационных изображений для определения водной поверхности и суши

4.4.1. Принцип применения алгоритмов. Так как разработанные в главе 3 алгоритмы в большинстве случаев являются дополнительным шагом обработки, целесообразно описать предполагаемую последовательность их использования в реальной системе обработки данных ДЗЗ.

Основополагающим фактором принятия решений является результат сегментации по АС. Поскольку при штатной обработке изображений нет сформированных эталонных масок, невозможно определить полученную достоверность. В таком случае оператор должен визуально оценить результат сегментации, сравнив его с исходным радиолокационным изображением, и принять решение, необходима ли дополнительная обработка. Если она необходима, то можно использовать алгоритм комплексирования либо уточнить результаты с помощью маски классов (при наличии теневых склонов рельефа). Маску классов можно использовать и третьим этапом после комплексирования.

В случае если получаемые результаты оператор считает недостаточно качественными, целесообразно выполнить сегментацию целиком на основе маски классов. Следует отметить, что этот вариант алгоритма можно использоваться непосредственно вместо АС, а не в качестве последней альтернативы.

Таким образом, разработанные алгоритмы сегментации можно применять в разной последовательности, в соответствии с решениями оператора.

4.4.2. Специальное программное обеспечение. Практическая реализация предложенных в диссертации алгоритмов сегментации радиолокационных изображений для определения водной поверхности и суши выполнена в Научно-исследовательском центре обработки аэрокосмических изображений (НИИ «Фотон») Рязанского государственного радиотехнического университета имени В.Ф.

Уткина по хоздоговорам с АО «Ракетно-космический центр «Прогресс» (г. Самара) в рамках создания космической системы «Обзор-Р».

Алгоритмы, предложенные в диссертации, реализованы в виде программного модуля (разработан на языке C++ в среде обработки Microsoft Visual Studio 2022 для операционной системы Windows) в специальном программном обеспечении высокоуровневой обработки радиолокационной информации космического аппарата «Обзор-Р» №1 (СПО ВО). СПО ВО функционирует на универсальной платформе быстрой разработки программ обработки данных ДЗЗ «ER-Set» [107, 108], созданной в НИИ «Фотон» РГРТУ.

Реализация программного модуля выполнена с использованием специализированного для «ER-Set» пользовательского интерфейса, с помощью которого можно открывать исходные изображения, визуализировать полученные данные и сохранять результаты обработки. Интеграция модуля в СПО ВО и его взаимодействие с другими модулями основаны на технологии «именованных функций» [109], позволяющей обмениваться данными между различными программными модулями.

Работоспособность и эффективность предложенных алгоритмов сегментации радиолокационных изображений в СПО ВО подтверждена Актом об использовании результатов кандидатской диссертации от «АО «РКЦ «Прогресс» (см. Приложение).

Основные результаты

1. Проведены экспериментальные исследования предложенного алгоритма АС, основанного на детерминированном алгоритме кластеризации, на 80 натуральных радиолокационных изображениях для текстурных признаков энергии, гомо-

генности и энтропии. Все полученные результаты сегментации имели достоверность не менее 90 %, обладали свойством повторяемости и для признаков энергии и гомогенности позволили снизить время вычислений в среднем примерно на 45 %.

2. Проведены экспериментальные исследования предложенного алгоритма комплексирования результатов сегментации многоканального изображения с помощью взвешенного голосования на 15 полнополяризационных радиолокационных изображениях. Среднее повышение достоверности составило от 0,74 % до 0,97 % относительно АС для первого варианта алгоритма и от 0,85 % до 1,26 % – для второго варианта. Максимальный прирост по обоим вариантам составил до 2,5 %.

3. Проведены экспериментальные исследования предложенного алгоритма формирования маски классов поверхности по данным ЦМР. Для изображений с теньевыми склонами рельефа получено среднее повышение достоверности на 2,98 % и максимальное – на 4,67 % при использовании маски классов в качестве инструмента уточнения результатов сегментации. В случае использования маски классов для получения независимых результатов сегментации достоверность составила не менее 93 %.

4. Рассмотрены особенности практической реализации предложенных алгоритмов в виде программного модуля СПО ВО.

Заключение

В диссертации предложен ряд алгоритмов, позволяющих повысить повторяемость и достоверность сегментации радиолокационных изображений для определения водной поверхности и суши в системах обработки данных дистанционного зондирования Земли. Основные результаты работы состоят в следующем.

1. Выполнен анализ существующих алгоритмов сегментации водной поверхности и суши на радиолокационных изображениях. Определен основной недостаток наиболее универсального решения на основе кластеризации по методу k -средних. Определены актуальные направления научных исследований в области повышения повторяемости и достоверности результатов целевой сегментации, которые составили основное содержание диссертации в виде Положений, вынесенных на защиту.

2. Разработан алгоритм сегментации АС радиолокационных изображений для определения водной поверхности и суши на основе детерминированного алгоритма адаптивной кластеризации по максимумам гистограммы (**Положение 1**). Проведено сравнение предложенного алгоритма с ближайшим аналогом на основе K-Means++. Показана наибольшая средняя по четырем каналам (видам поляризации) достоверность результатов сегментации, а также снижение общего времени вычислений на 35–50 % благодаря большей скорости определения кластеров. Полученные во всех экспериментах значения достоверности сегментации с помощью АС составили не менее 90 %.

3. Разработан алгоритм комплексирования результатов сегментации многоканального радиолокационного изображения с помощью взвешенного голосования (**Положение 2**). Предложены два варианта алгоритма с различными значениями параметров взвешенного голосования, в зависимости от набора исходных

данных. В проведенных экспериментах было достигнуто повышение достоверности сегментации до 2,5 % относительно результатов, полученных по АС.

4. Разработан алгоритм формирования маски классов поверхности на основе анализа относительных значений высот по данным цифровой модели рельефа (**Положение 3**). Предложены два варианта применения алгоритма: для уточнения имеющихся результатов сегментации при наличии на изображении теневых склонов рельефа (повышение достоверности составило до 4,7 %) и для получения новых (с достоверностью не менее 93 %).

Список сокращений

АКМГ	–	адаптивная кластеризация по максимумам гистограммы;
ДЗЗ	–	дистанционное зондирование Земли;
ЛЧМ	–	линейная частотная модуляция;
РСА	–	радиолокатор с синтезированной апертурой антенны;
СПО ВО	–	специальное программное обеспечение высокоуровневой обработки радиолокационной информации космического аппарата «Обзор-Р» №1;
ЦМР	–	цифровая модель рельефа;
GLCM	–	Gray-Level Co-occurrence Matrix;
WCSS	–	Within-Cluster Sum of Squares.

Список литературы

1. Чандра А.М., Гош С.К. Дистанционное зондирование и географические информационные системы / М.: Техносфера, 2008. 312 с.
2. Шовенгердт Р.А. Дистанционное зондирование. Модели и методы обработки изображений / М.: Техносфера, 2010. 560 с.
3. Гарбук С.В., Гершензон В.Е. Космические системы дистанционного зондирования Земли / М.: Издательство А и Б, 1997. 296 с.
4. Кашкин В.Б., Сухинин А.И. Дистанционное зондирование Земли из космоса / Цифровая обработка изображений: учебное пособие. М.: Логос, 2001. 264 с.
5. Schott J. Remote sensing. The image chain approach / Oxford University Press Inc., 2007. 701 p.
6. В.К. Злобин, В.В. Еремеев, А.Е. Кузнецов. Обработка изображений в геоинформационных системах: учебное пособие / Рязань: Рязан. Гос. Радиотехн. Университет, 2006. 264 с.
7. Кронберг П. Дистанционное изучение Земли / М.: Мир, 1988. 350 с.
8. Дейвис Ш.М., Ландгребе Д.А., Филлипс Т.Л. и др. Дистанционное зондирование: количественный подход / Под ред. Ф. Свейна и Ш. Дейвис. – М.: Недра, 1983. 415 с.
9. Cumming I.G., Wong F.H. Digital processing of synthetic aperture radar data: algorithms and implementation / Artech House, 2005. 660 p.
10. Верба В.С., Неронский Л.Б., Осипов И.Г., Турук В.Э. Радиолокационные системы землеобзора космического базирования / М.: Радиотехника, 2010. 680 с.
11. Кондратенков Г.С., Фролов А.Ю. Радиовидение. Радиолокационные системы дистанционного зондирования Земли / М.: Радиотехника, 2005. 368 с.

12. Goodman J.W. Speckle Phenomena in Optics: Theory and Applications. / Englewood, CO: Roberts & Company Publishers, 2020. 560 p.
13. Гусев С.И., Кузнецов Л.Л. Сравнительный анализ методов поляриметрической классификации объектов на радиолокационных изображениях // Современные технологии в науке и образовании – СТНО-2024. Сб. тр. VII Междунар. науч.-техн. фор. В 10-ти т. Рязань: РГРТУ, 2024. Т. 6. С. 34–38.
14. Гусев С.И., Кузнецов Л.Л., Ушенкин В.А. Обнаружение водной поверхности на полнополяризационных радиолокационных изображениях // Современные технологии в науке и образовании – СТНО-2025. Сб. тр. VIII Междунар. науч.-техн. фор. В 10-ти т. Рязань: РГРТУ, 2025. Т. 6. С. 58–61.
15. Гусев С.И., Кузнецов Л.Л. Метод кластеризации на основе анализа максимумов гистограммы в задачах сегментации изображений в системах дистанционного зондирования Земли. // Перспективы науки. 2025. № 6(189). С. 39–43.
16. Гусев С.И., Кузнецов Л.Л. Принятие решений о классе пикселей многоканального радиолокационного изображения по результатам классификации пикселей отдельных каналов в системах дистанционного зондирования Земли. // Перспективы науки. 2025. № 7(190). С. 15–19.
17. Гусев С.И., Кузнецов Л.Л. Классификация объектов радиолокационных изображений по признаку принадлежности к водной поверхности на основе текстурного анализа в системах дистанционного зондирования Земли // Научно-технические технологии в космических исследованиях Земли. 2025. Т. 17. № 3. С. 22–28.
18. Гусев С.И., Кузнецов Л.Л. Сравнительный анализ методов поляриметрической классификации объектов при обработке радиолокационных изображений // Космические технологии - 2024. Сб. науч. стат. Междунар. межведомственнонауч.-техн. конф. Москва: МИРЭА, 2024. С. 298–300.

19. Кузнецов Л.Л. Алгоритм повышения точности классификации объектов радиолокационных изображений по критерию принадлежности к водной поверхности или суше с использованием цифровой модели рельефа // Вестник РГРТУ. 2026. № 95. С. 202–214.

20. Кузнецов Л.Л. Алгоритм обнаружения водной поверхности на радиолокационных изображениях с помощью цифровой модели рельефа в системах ДЗЗ // Новые информационные технологии в научных исследованиях. Материалы XXX Всероссийской научно-технической конференции студентов, молодых ученых и специалистов. Рязань: РГРТУ, 2025. С. 138–139.

21. Кузнецов Л.Л. Обзор методов классификации объектов на радиолокационных изображениях // Современные технологии в науке и образовании – СТНО-2023. Сб. тр. VI Междунар. науч.-техн. фор. В 10-ти т. Под общ. ред. О.В. Миловзорова. Рязань: РГРТУ, 2023. Т. 6. С. 172–175.

22. Кузнецов Л.Л. Применение текстурного анализа для классификации объектов на радиолокационных изображениях // Материалы тринадцатой научно-технической конференции «Актуальные проблемы создания космических систем дистанционного зондирования Земли». Москва: ВНИИЭМ, 2025. С. 104–105.

23. Curlander J.C., McDonough R.N. Synthetic Aperture Radar: Systems and Signal Processing / Wiley, 1991.

24. Ушенкин В.А. Алгоритмы высокоточной обработки интерферометрической информации от система дистанционного зондирования Земли на основе 3D-анализа наблюдаемой сцены : дис. ... канд. техн. наук : 05.13.01 / Ушенкин Виктор Андреевич. Рязань, 2017. 165 с.

25. Егошкин Н.А., Москвитин А.Э. Моделирование работы космического радиолокатора высокого разрешения // 6-я международная научно-техническая конференция «Космонавтика. Радиоэлектроника. Геоинформатика»: Тез. докл. Рязань: Рязан. гос. радиотехн. университет. 2013. 281 с.

26. Rocca F., Cafforio C., Prati C. Synthetic aperture radar: a new application for wave equation techniques // *Geophysical Prospecting*. 1989. Vol. 37. P. 809–830.
27. Cafforio C., Prati C., Rocca F. SAR data focusing using seismic migration techniques // *IEEE Trans. on Aerospace and Electronic Systems*. 1991. Vol. 27 (2). P. 194–207.
28. Wu C. A digital system to produce imagery from SAR data // *AIAA Conference: System Design Driven by Sensors*. 1976.
29. Wu C. Processing of SEASAT SAR data // *SAR Technology Symposium*. 1977.
30. Cumming I.G., Bennett J.R. Digital processing of SEASAT SAR data // *IEEE 1979 International Conference on Acoustics, Speech and Signal Processing*. 1979. P. 710–718.
31. Bennett J.R., Gunning I.G. A digital processor for the production of SEASAT synthetic aperture radar imagery // *Proc. SURGE Workshop*. 1979.
32. Gunning I.G., Wong F.H., Raney R.K. A SAR processing algorithm with no interpolation // *Proc. Int. Geoscience and remote Sensing Symp*. 1992. P. 376–379.
33. Raney R.K., Runge N., Bamler R., Cumming I.G., Wong F.H. Precision SAR processing using chirp scaling // *IEEE Trans. Geoscience and Remote Sensing*. 1994. Vol. 32 (4). P. 786–799.
34. Moreira A., Mittermayer J., Scheiber R. Extended chirp scaling algorithm for air and spaceborne SAR data processing in Stripmap and ScanSAR imaging modes // *IEEE Trans. on Geoscience and Remote Sensing*. 1996. Vol. 34 (5). P. 1123–1136.
35. Mittermayer J., Scheiber R., Moreira A. The extended chirp scaling algorithm for ScanSAR data processing // *Proc. European Conference on Synthetic Aperture Radar*. 1996. P. 517–520.

36. Mittermayer J., Moreira A. A generic formulation of the extended chirp scaling algorithm (ECS) for phase preserving ScanSAR and SpotSAR processing // Proc. Int. Geoscience and Remote Sensing Symp. 2000. Vol. 1. P. 108–110.
37. Cumming I.G., Lim J. The design of a digital breadboard processor for the ESA remote sensing satellite synthetic aperture radar. – Technical report, MacDonald Dettwiler, Richmond, BC, July 1981. Final report for ESA Contract No. 3998/79/NL/HP(SC).
38. Okkes R., Cumming I.G. Method of and apparatus for processing data generated by a synthetic aperture radar system. – European Patent No. 0048704, filed September 15, 1981, granted February 20, 1985.
39. ГОСТ Р 51794-2008. Глобальные навигационные спутниковые системы. Системы координат. Методы преобразований координат определяемых точек. – М.: Стандартинформ, 2009. 29 с.
40. Космическая съемка высокого и сверхвысокого разрешения: радарные спутники [Электронный ресурс]. Режим доступа: <http://sovzond.ru/products/spatial-data/satellites/#>.
41. Umbra [Электронный ресурс]. Режим доступа: https://catalyst.earth/catalyst-system-files/professional-help/references/gdb_r/Umbra.html.
42. Next-Gen Satellite Technology [Электронный ресурс]. Режим доступа: <https://www.capellaspace.com/technology>.
43. Imaging modes [Электронный ресурс]. Режим доступа: <https://www.iceye.com/sar-data/imaging-modes>.
44. NISAR – NASA ISRO SAR Mission [Электронный ресурс]. Режим доступа: <https://bhoonidhi.nrsc.gov.in/NISAR/>.
45. Guo Z., et al. Water-Body Segmentation for SAR Images: Past, Current and Future // Remote Sens. 2022. Vol. 14 (7): 1752.

46. Jain A.K. Data clustering: 50 years beyond K-means // *Pattern Recognition Letters*. 2010. Vol. 31(8). P. 651–666.
47. Fisher W. D. On Grouping for Maximum Homogeneity // *Journal of the American Statistical Association*. 1958. Vol. 53(284). P. 789–798.
48. Hu H., Dai G., Wang M., Yi P. Detection of river in SAR images // In *Proceedings of the 2012 8th International Conference on Information Science and Digital Content Technology (ICIDT2012)*. 2012. P. 632–635.
49. Liu Z., Li F., Li N., Wang R., Zhang H. A Novel Region-Merging Approach for Coastline Extraction from Sentinel-1A IW Mode SAR Imagery // *IEEE Geosci. Remote Sens. Lett.* 2016. Vol. 13. P 324–328.
50. Wu L., et al. Discrimination of Algal-Bloom Using Spaceborne SAR Observations of Great Lakes in China // *Remote Sens.* 2018. Vol. 10: 767.
51. Li N., Niu S. High-precision water segmentation from synthetic aperture radar images based on local super-resolution restoration technology // *J. Radars*. 2020. Vol. 9. P. 174–184.
52. Wang M., Zhou S., Bai H., Ma N., Ye S. SAR Water Image Segmentation Based on GLCM and Wavelet Textures // In *Proceedings of the 2010 6th International Conference on Wireless Communications Networking and Mobile Computing (WiCOM)*. 2010. P. 1–4.
53. Zhu J., Guo H., Fan X., Shao Y. A wavelet transform method to detect boundaries between land and water in SAR image // In *Proceedings of the IGARSS 2004. 2004 IEEE International Geoscience and Remote Sensing Symposium*. 2004. P. 4262–4264.
54. Kass M., Witkin A., Terzopoulos D. Snakes: Active contour models // *Int. J. Comput. Vis.* 1988. Vol. 1. P. 321–331.
55. Cohen L. On active contour models and balloons // *CVGIP Image Underst.* 1991. Vol. 53. P. 211–218.

56. Niedermeier, A.; Romaneessen, E.; Lehner, S. Detection of coastlines in SAR images using wavelet methods // *IEEE Trans. Geosci. Remote Sens.* 2000. Vol. 38. P. 2270–2281.
57. Chan T., Vese L. Active contours without edges // *IEEE Trans. Image Processing.* 2001. Vol. 10. P. 266–277.
58. Yin J., Liu X., Yang J., Chu C., Chang Y. PolSAR Image Classification Based on Statistical Distribution and MRF // *Remote Sens.* 2020. Vol. 12: 1027.
59. Lee J., Grunes M. Classification of multi-look polarimetric SAR data based on complex Wishart distribution // *In Proceedings of the NTC-92: National Telesystems Conference.* 1992. Vol. 7. P. 21–24.
60. Deng H., Claudi D. Unsupervised segmentation of synthetic aperture Radar sea ice imagery using a novel Markov random field model // *IEEE Trans. Geosci. Remote Sens.* 2005. Vol. 43. P. 528–538.
61. Latini D., Frate F., Palazzo F., Minchella A. Coastline extraction from SAR COSMO-SkyMed data using a new neural network algorithm // *In Proceedings of the 2012 IEEE International Geoscience and Remote Sensing Symposium.* 2012. P. 5975–5977.
62. Long J., Shelhamer E., Darrell T. Fully convolutional networks for semantic segmentation // *In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.* 2015. P. 3431–3440.
63. Kim M., Oh H., Lee S., Choi Y., Han S. Deep Learning Based Water Segmentation Using KOMPSAT-5 SAR Images // *In Proceedings of the 2021 IEEE International Geoscience and Remote Sensing Symposium IGARSS.* 2021. P. 4055–4058.
64. Lloyd S. Least Squares Quantization in PCM // *IEEE Transactions on Information Theory.* 1982. Vol. 28 (2). P. 129–137.
65. Arthur D., Vassilvitskii S. K-means++: The Advantages of Careful Seeding. / *SODA*, 2007. 11 p.

66. Comaniciu D., Meer P. Mean shift: A robust approach toward feature space analysis // *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 2002. Vol. 24 (5). P. 603–619.
67. Fukunaga K., Hostetler L. The estimation of the gradient of a density function, with applications in pattern recognition // *IEEE Transactions on Information Theory*. 1975. Vol. 21 (1). P. 32–40.
68. Campello R.J., Moulavi D., Sander J. Density-based clustering based on hierarchical density estimates // *In PAKDD*. 2013. P. 160–172.
69. McInnes L., Healy J., Astels S. hdbscan: Hierarchical density based clustering // *Journal of Open Source Software*. 2017. Vol. 2 (11). P. 205.
70. Ng A.Y., Jordan M.I., Weiss Y. On spectral clustering: Analysis and an algorithm // *Advances in Neural Information Processing Systems*. 2002. Vol. 14. P. 849–856.
71. Von Luxburg U. A tutorial on spectral clustering // *Statistics and Computing*. 2007. Vol. 17 (4). P. 395–416.
72. McLachlan G., Peel D. *Finite Mixture Models* / Wiley, 2000.
73. Bishop C.M. *Pattern Recognition and Machine Learning* / Springer, 2006.
74. Pedregosa F. et al. *Scikit-learn: Machine Learning in Python* // *JMLR*. 2011. Vol. 12.
75. Otsu N. A Threshold Selection Method from Gray-Level Histograms // *IEEE Transactions on Systems, Man, and Cybernetics*. 1979. Vol. 9 (1). P. 62–66.
76. Leung T., Malik J. Representing and Recognizing the Visual Appearance of Materials Using Three-Dimensional Textons // *IJCV*. 2001. Vol. 43 (1).
77. Heckbert P. Color Image Quantization for Frame Buffer Display / *SIGGRAPH*, 1982.
78. Ester M. A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases / *KDD*, 1996.

79. Синёва А.А. Поляризационная радиолокация для обнаружения и идентификации пленочных загрязнений моря // М.: Труды МФТИ. 2014. Т. 6. № 3. С. 129–141.
80. Егошкин Н.А., Еремеев В.В., Москвитин А.Э., Ушенкин В.А. Обработка информации от современных космических систем радиолокационного наблюдения Земли. / М.: ФИЗМАТЛИТ, 2019. 320 с. + 32 с. цв. вкл.
81. Cameron W.L., Leung L.K. Feature Motivated Polarization Scattering Matrix Decomposition // Proc. IEEE International Radar Conference. 1990. P. 549–557.
82. Lee J.S., Pottier E. Polarimetric Radar Imaging: from Basic to Applications. / Boca Raton, London, New York: CRC Press, 2009. 398 p.
83. Lee J.S., Grunes M.R., Ainsworth T.L., Du L.J., Schuler D.L., Cloude S.R. Unsupervised classification using polarimetric decomposition and the complex Wishart classifier // IEEE Trans. On Geosciences and Remote Sensing. 1999. Vol. 37 (5). P. 2249–2258.
84. Haralick R.M., Shanmugam K., Dinstein I. Textural Features for Image Classification // IEEE Trans. SMC. 1973. Vol. 3 (6). P. 610–621.
85. Tuceryan M., Jain A.K. Texture Analysis. In: The Handbook of Pattern Recognition and Computer Vision // World Scientific. 1998. P. 207–248.
86. Ulaby F.T., Long D.G. Microwave Radar and Radiometric Remote Sensing / University of Michigan Press, 2014. 1013 p.
87. Lee J.S. Digital image enhancement and noise filtering by use of local statistics. // IEEE TPAMI. 1980. Vol. 2 (2). P. 165–168.
88. Frost V.S., et al. A model for radar images and its application to adaptive digital filtering of multiplicative noise // IEEE TPAMI. 1982. Vol. 4 (2). P. 157–166.
89. Lopes A., et al. Structure detection and statistical adaptive speckle filtering in SAR images // IJRS. 1993. Vol. 14 (9). P. 1735–1758.

90. Maillard P. Comparing texture analysis methods through classification // PE&RS. 2003. Vol. 69 (4). P. 357–367.
91. Soille P. Morphological Image Analysis: Principles and Applications / Springer, 2003. 391 p.
92. Ковалева И.Л. Текстурные признаки изображений. Учебное издание / БНТУ, 2010. 25 с.
93. Фраленко В.П. Методы текстурного анализа изображений, обработка данных дистанционного зондирования Земли // Программные системы: теория и приложения. 2014. № 4 (22). С. 19–39.
94. Vovk O.L. Evaluation of statistical features for texture classification // The Visnyk of the SSU. 2004. Vol. 71 (12). P. 98–105.
95. Антощук С.Г., Сербина Н.А. Система распознавания текстурных изображений при экологическом мониторинге // Искусственный интеллект. 2002. Т. 4. С. 406–413.
96. Anfinsen S.N., Doulgeris A.P., Eltoft T. Estimation of the Equivalent Number of Looks in Polarimetric SAR Imagery // IEEE Transactions on Geoscience and Remote Sensing. 2009. Vol. 47 (11). P. 3795–3809.
97. Silverman B.W. Density Estimation for Statistics and Data Analysis / Chapman & Hall, 1986.
98. Scott D.W. Multivariate Density Estimation: Theory, Practice, and Visualization / Wiley, 1992.
99. Хацкевич В.Л. О некоторых экстремальных свойствах средних значений и математических ожиданий случайных величин / Вестник ВГТУ, 2011.
100. Kanungo T., Mount D.M., Netanyahu N.S., Piatko C.D., Silverman R., Wu A.Y. An efficient k-means clustering algorithm: Analysis and implementation // IEEE Transactions on Pattern Analysis and Machine Intelligence. 2002. Vol. 24 (7). P. 881–892.

101. Fisher R.A. *Statistical Methods for Research Workers* / Oliver and Boyd, 1930.
102. Woodhouse I.H., Cloude S.R., Papathanassiou K.P. Forest height retrieval from commercial X-band SAR products // *Transactions on Geoscience and Remote Sensing*. 2006. Vol. 44 (9) P. 2364–2374.
103. Kittler J. On Combining Classifiers // *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*. 1998. Vol. 20 (3). P. 226–239.
104. Kuncheva L.I. *Combining Pattern Classifiers: Methods and Algorithms* / Wiley-Interscience, 2004. 360 p.
105. Hengl T., Reuter H.I. *Geomorphometry: Concepts, Software, Applications* / Elsevier, 2009. 765 p.
106. Sun D., Gao G., Huang L., Liu Y., Liu D. Extraction of water bodies from high-resolution remote sensing imagery based on a deep semantic segmentation network // *Sci Rep*. 2024. Vol. 14 (1): 14604.
107. Побаруев В. И. Унифицированная программная платформа создания средств обработки данных дистанционного зондирования Земли – «Er-Set» [Текст] / В. И. Побаруев // *Вестник Рязанского государственного радиотехнического университета*. 2016. № 55. С. 95–103.
108. Универсальная платформа быстрой разработки приложений для обработки данных дистанционного зондирования Земли «ER-Set» [Текст]: пат. 2013610968 Рос. Федерация / В. И. Побаруев (Российская Федерация); ФГБОУ ВО «РГРТУ» (RU). – Заявл. 09.01.2013.
109. Побаруев В. И. Организация межпрограммного взаимодействия в сложных системах методом «ассоциативного» интерфейса [Текст] / В. И. Побаруев // *Вестник Рязанского государственного радиотехнического университета*. 2013. № 2. С. 56–60.

Приложение

АКТЫ И СВИДЕТЕЛЬСТВА ОБ ИСПОЛЬЗОВАНИИ РЕЗУЛЬТАТОВ ДИССЕРТАЦИОННОЙ РАБОТЫ



АКЦИОНЕРНОЕ ОБЩЕСТВО «РАКЕТНО-КОСМИЧЕСКИЙ ЦЕНТР «ПРОГРЕСС»

(АО «РКЦ «ПРОГРЕСС»)

ул. Земеца, д.18, г. Самара, 443009, тел. (846) 955-13-61, факс (846) 992-65-18, E-mail: mail@samspace.ru
ОКПО 43892776, ИНН 6312139922, КПП 997450001

УТВЕРЖДАЮ

Первый заместитель

генерального директора –

генеральный конструктор

АО «РКЦ «Прогресс», д.т.н



Р.Н. Ахметов*

2026 г.

АКТ

об использовании результатов кандидатской диссертации Кузнецова Л.Л.
«Алгоритмы сегментации радиолокационных изображений
для определения водной поверхности и суши
в системах обработки данных дистанционного зондирования Земли»

В рамках ОКР по созданию космического комплекса (КК) «Обзор-Р» АО «РКЦ «Прогресс» (Заказчик) совместно с ФБГОУ ВО «Рязанский государственный радиотехнический университет им. В.Ф. Уткина» (Исполнитель) выполняет разработку математических и программных средств наземной обработки поступающей информации.

В кандидатской диссертации Л.Л. Кузнецова предложен и реализован ряд оригинальных решений по сегментации радиолокационных изображений на основе текстурного анализа, позволяющих выполнить тематическую высокоуровневую обработку радиолокационной информации с высокой точностью.

Предложенные решения реализованы в специальном программном обеспечении высокоуровневой обработки (СПО ВО) радиолокационной информации космического аппарата «Обзор-Р» №1.

СПО ВО прошло наземную экспериментальную отработку, показавшую эффективность предложенных решений. СПО ВО предназначено для использования в Ракетно-космическом центре «Прогресс» при создании комплекса технических средств приема и обработки информации КК «Обзор-Р».

Первый заместитель генерального
конструктора – первый
заместитель начальника ЦСКБ

Филатов Артем Викторович**

Заместитель главного
конструктора, к.т.н.

Шилов Лев Борисович***

* ул. Земеца, д.18 г. Самара, 443009; тел.: (846)992-65-29; e-mail ARN@samspace.ru

**ул. Земеца, д.18 г. Самара, 443009; тел.: (846)992-64-89; e-mail Filatov.AV@samspace.ru


***ул. Земеца, д.18 г. Самара, 443009; тел.(846)228-96-90; e-mail shilov@samspace.ru

Р.Н. Ахметов, А.В. Филатов, Л.Б. Шилов выражают согласие на включение своих персональных данных в аттестационные документы соискателя ученой степени кандидата технических наук Л.Л. Кузнецова и их дальнейшую обработку.



УТВЕРЖДАЮ

Проректор по образовательной деятельности, к.п.н., доцент

 Е. А. Соколова
«14» апреля 2026 г.

АКТ

об использовании результатов диссертации Кузнецова Л.Л. «Алгоритмы сегментации радиолокационных изображений для определения водной поверхности и суши в системах обработки данных дистанционного зондирования Земли», представленной на соискание учёной степени кандидата технических наук, в образовательном процессе ФГБОУ ВО «РГРТУ»

Настоящим актом удостоверяется, что результаты исследований кандидатской диссертации Кузнецова Л.Л. «Алгоритмы сегментации радиолокационных изображений для определения водной поверхности и суши в системах обработки данных дистанционного зондирования Земли» используются в учебном процессе кафедры «Космические технологии» ФГБОУ ВО «РГРТУ» по направлению подготовки 09.04.01 «Информатика и вычислительная техника» (профиль «Инжиниринг космических информационных систем»).

Предлагаемое в диссертации алгоритмическое обеспечение, а также разработанные программы обработки радиолокационных данных дистанционного зондирования Земли для ЭВМ используются при подготовке лекций, практических и лабораторных занятий по дисциплинам «Геоинформационные системы и технологии» и «Аэрокосмические системы и технологии обработки информации».

Проректор по научной работе и инновациям, заведующий кафедрой «Космические технологии», д.т.н., доцент




С. И. Гусев

Профессор кафедры «Космические технологии», д.т.н., профессор

А. И. Таганов

Доцент кафедры «Космические технологии», к.т.н., доцент



О. А. Бодров

РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025693785

**Программа уточнения классификации пикселей
радиолокационного изображения по признаку
принадлежности к водной поверхности или суше с
помощью цифровой модели рельефа**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Рязанский государственный радиотехнический
университет имени В.Ф. Уткина» (RU)*

Автор(ы): *Кузнецов Леонид Львович (RU)*

Заявка № 2025693208

Дата поступления 02 декабря 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 02 декабря 2025 г.

*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e4f7ad8d531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 04.03.2025 по 28.11.2026

Ю.С. Зубов



РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2025693786

**Программа текстурной классификации пикселей
радиолокационного изображения по признаку
принадлежности к водной поверхности или суше**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Рязанский государственный радиотехнический
университет имени В.Ф. Уткина» (RU)*

Автор(ы): *Кузнецов Леонид Львович (RU)*

Заявка № 2025693209

Дата поступления 02 декабря 2025 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 02 декабря 2025 г.

*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e4f7add8d531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 04.09.2025 по 28.11.2026

Ю.С. Зубов



РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2026662503

Программа объединения результатов текстурной и поляриметрической классификаций пикселей радиолокационного изображения по признаку принадлежности к водной поверхности или суше

Правообладатель: *Федеральное государственное бюджетное образовательное учреждение высшего образования «Рязанский государственный радиотехнический университет имени В.Ф. Уткина» (RU)*

Автор(ы): *Кузнецов Леонид Львович (RU)*

Заявка № 2026662416

Дата поступления 29 апреля 2026 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 29 апреля 2026 г.

*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e4f7ad8d531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 04.03.2025 по 28.11.2026

Ю.С. Зубов



РОССИЙСКАЯ ФЕДЕРАЦИЯ



СВИДЕТЕЛЬСТВО

о государственной регистрации программы для ЭВМ

№ 2026662605

**Программа классификации объектов фрагмента
цифровой модели рельефа по признаку принадлежности
к водной поверхности или суше**

Правообладатель: *Федеральное государственное бюджетное
образовательное учреждение высшего образования
«Рязанский государственный радиотехнический
университет имени В.Ф. Уткина» (RU)*

Автор(ы): *Кузнецов Леонид Львович (RU)*

Заявка № 2026662479

Дата поступления 29 апреля 2026 г.

Дата государственной регистрации

в Реестре программ для ЭВМ 29 апреля 2026 г.

*Руководитель Федеральной службы
по интеллектуальной собственности*

ДОКУМЕНТ ПОДПИСАН ЭЛЕКТРОННОЙ ПОДПИСЬЮ
Сертификат 00a570e4f7add8d531b4b8818e75f29506
Владелец **Зубов Юрий Сергеевич**
Действителен с 04.05.2025 по 28.11.2026

Ю.С. Зубов

